

### Axiomy $(\Omega, \mathcal{F} \subseteq \mathcal{P}(\Omega), P: \mathcal{F} \rightarrow [0,1])$

- $\emptyset, \Omega \in \mathcal{F}$
- $A \in \mathcal{F} \Rightarrow A^c \in \mathcal{F}$
- $A_1, A_2, \dots \in \mathcal{F} \Rightarrow \cup A_i \in \mathcal{F}$
- $P(\Omega) = 1$
- $P(\cup A_i) = \sum P(A_i)$

### Podmíněná ps

$$P(A \cap B) = P(B) \cdot P(A|B)$$

$$P(A_1 \cap A_2 \cap A_3) = P(A_1) \cdot P(A_2|A_1) \cdot P(A_3|A_1 \cap A_2)$$

$$P(A) = \sum_i P(B_i) \cdot P(A|B_i), B = \text{rozdělod } \Omega$$

$$P(B_j|A) = \frac{P(B_j \cap A)}{P(A)} = \frac{P(B_j) \cdot P(A|B_j)}{P(A)}$$

$$A \perp B \equiv P(A \cap B) = P(A) \cdot P(B)$$

$$A \perp_c B \equiv P(A \cap B|C) = P(A|C) \cdot P(B|C)$$

### Diskrétní

- $X \sim \text{Ber}(p)$   
 $f_X(x) = p, f_X(0) = 1-p$   
 $E = p \quad \text{Var} = p(1-p)$
- $X \sim \text{Geom}(p)$   
 $f_X(x) = (1-p)^{x-1} p$   
 $E = \frac{1}{p} \quad \text{Var} = \frac{1-p}{p^2}$
- $X \sim \text{Bin}(n, p)$   
 $f_X(x) = \binom{n}{x} p^x (1-p)^{n-x}$   
 $E = np \quad \text{Var} = np(1-p)$
- $X \sim \text{Pois}(\lambda) \approx \text{Bin}(n, \frac{\lambda}{n})$   
 $f_X(x) = \frac{\lambda^x}{x!} e^{-\lambda}, \lambda > 0$   
 $E = \text{Var} = \lambda$

### ROZDĚLENÍ

- $X \sim U(a, b)$   
 $f_X(x) = \frac{1}{b-a}, x \in [a, b]$   
 $E = \frac{a+b}{2} \quad \text{Var} = \frac{(b-a)^2}{12}$
- $X \sim \text{Exp}(\lambda) \dots \lambda > 0$   
 $F_X(x) = 1 - e^{-\lambda x}, x > 0$   
 $E = \frac{1}{\lambda} \quad \text{Var} = \frac{1}{\lambda^2}$
- $X \sim N(0, 1)$   
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \rightarrow \Phi$
- $X \sim N(\mu, \sigma^2) \rightarrow X = \mu + \sigma Z$   
 $f_X(x) = \frac{1}{\sigma} \varphi\left(\frac{x-\mu}{\sigma}\right)$   
 $F_X(x) = \Phi\left(\frac{x-\mu}{\sigma}\right)$
- $X_i \sim N(\mu_i, \sigma_i^2) \Rightarrow \sum X_i \sim N(\sum \mu_i, \sum \sigma_i^2)$

### Spojité

### Diskrétní n.v. $X: \Omega \rightarrow \mathbb{R}$

- $\text{Im}(X)$  je spočetná
  - $\forall x \in \mathbb{R}: \{X=x\} \in \mathcal{F}$
- $$\Rightarrow f_X(x): x \mapsto P\{X=x\}$$

### vlastnosti E - linearita

$$EX = \sum_{m=0}^{\infty} P\{X > m\}, \text{Im}(X) \subseteq \mathbb{N}$$

$$X \perp Y \Rightarrow EXY = EX \cdot EY$$

### vlastnosti Var $X := E[(X-EX)^2]$

$$\text{var } X = E[X^2] - (EX)^2$$

$$= E[X(X-1)] + EX - (EX)^2$$

$$\text{Var}(aX+b) = a^2 \text{Var } X$$

$$X \perp Y \Rightarrow \text{Var}(X+Y) = \text{Var } X + \text{Var } Y$$

$$CV_X := \frac{\sigma_X}{EX} \dots \text{var. coef}$$

$$\text{Var}(X+Y) = \text{Var } X + \text{Var } Y + 2\text{cov}(X, Y)$$

$$\rightarrow \text{cov}(X, Y) := E[(X-EX)(Y-EY)]$$

$$= E[XY] - EX \cdot EY$$

$$\rightarrow \text{cov}(X, aX+bY+c) = a \text{cov}(X, Y) + b \text{cov}(X, Y)$$

$$\rightarrow \rho(X, Y) := \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} \dots \text{korelace}$$

### Obecné n.v. $X: \Omega \rightarrow \mathbb{R}$

$$\forall x \in \mathbb{R}: \{X \leq x\} \in \mathcal{F}$$

$$F_X(x): x \mapsto P\{X \leq x\}$$

$$\rightarrow F_X \text{ je: neklesající, správa spoj.}$$

$$\rightarrow F_X(\infty) = 1, F_X(-\infty) = 0$$

### Diskrétní

$$EX = \sum_{x \in \text{Im } X} x \cdot f_X(x)$$

$$EX = \sum_{\omega \in \Omega} X(\omega) \cdot P\{\omega\}$$

$$Y := g(X) \Rightarrow f_{X,Y}(x,y) = \sum_{x: g(x)=y} f_X(x)$$

$$E[g(X)] = \sum_x g(x) f_X(x)$$

$$E[X|B] = \sum_x x \cdot P\{X=x|B\}$$

$$EX = \sum_x P(B_i) \cdot E[X|B_i]$$

$$h_{X,Y}(x,y) = P\{X=x, Y=y\}$$

$$h_X(x) = \sum_y h_{X,Y}(x,y)$$

$$P\{g(X,Y)=z\} = \sum_{x,y: g(x,y)=z} h_{X,Y}(x,y)$$

$$X \perp Y \equiv h_{X,Y} = h_X \cdot h_Y$$

$$P\{X+Y=z\} = \sum_x h_X(x) h_Y(z-x)$$

$$E[g(X,Y)] = \sum_{x,y} g(x,y) h_{X,Y}(x,y)$$

### VĚLICINY

$$EX = \int_{-\infty}^{\infty} x f_X(x) dx$$

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

$$\text{Var}(X) = E[(X-\mu)^2] = \int_{-\infty}^{\infty} x^2 f_X(x) dx - \mu^2$$

$$F_{X,Y}(x,y) = P\{X \leq x, Y \leq y\}$$

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

$$P\{(X,Y) \in S\} = \int_S f_{X,Y}(x,y) dx dy$$

$$f_{X,Y}(x,y) = \frac{\partial^2 F_{X,Y}}{\partial x \partial y}(x,y)$$

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

$$X \perp Y \equiv F_{X,Y} = F_X \cdot F_Y \Leftrightarrow f_{X,Y} = f_X \cdot f_Y$$

$$Z = X+Y \Rightarrow f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx$$

$$X \text{ je spojité} \equiv F_X(x) = \int_{-\infty}^x f_X(t) dt$$

$$f_X = F_X', f_X \geq 0, \int_{-\infty}^{\infty} f_X = 1$$

### Spojité

### Kvantilová fu

$$Q_X(p) = \min \{x \in \mathbb{R} \mid p \leq F_X(x)\} \rightarrow \text{medián} := Q_X\left(\frac{1}{2}\right)$$

### Nerovnosti:

$$\text{Markov: } X \geq 0 \Rightarrow P\{X \geq a\} \leq \frac{EX}{a} \Leftrightarrow P\{X \geq t \cdot EX\} \leq \frac{1}{t}$$

$$\text{Čebyšev: } \Delta > 0 \Rightarrow P\{|X-\mu| \geq t \cdot \sigma\} \leq \frac{1}{t^2} \rightarrow \text{nerovnost o pravě}$$

$$X \sim \text{Bin}(m, p), Y \sim \text{Bin}(n, p) \Rightarrow X+Y \sim \text{Bin}(m+n, p)$$

Zákonny velkých čísel

silný:  $P[\lim \bar{X}_n = \mu] = 1$   
 slabý:  $P[|\bar{X}_n - \mu| > \epsilon] = 0$   
 $\hookrightarrow \bar{X}_n \xrightarrow{P} \mu$  Lebesgue

$E\bar{X}_n = \frac{1}{n}(\sum E X_i) = \frac{n}{n} \mu = \mu$   
 $Var \bar{X}_n = \frac{1}{n^2} \sum Var X_i = \frac{n}{n^2} \sigma^2 = \frac{\sigma^2}{n}$   
 $\Rightarrow \sigma(\bar{X}_n) = \sigma/\sqrt{n}$  mez.  $X_i$

Centrální limitní věta

$X_1, \dots, X_n$  stejné r. m. u. v.  
 $Y_n := \frac{\bar{X}_n - E\bar{X}_n}{\sigma(\bar{X}_n)} = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \approx N(0,1)$

Intervale odhady

$\hookrightarrow$  mám  $\hat{\theta}$  odhad  $\theta$  } dolní horní odhad  
 $\hookrightarrow$  statistiky  $D \leq H$

$[D, H]$  je  $(1-\alpha)$ -CI  $\equiv P[D \leq \theta \leq H] = 1-\alpha$

Věta: Nekramý  $\hat{\theta}$  pro  $\theta$ ,  $\hat{\theta} \sim N(\mu, \sigma^2)$   
 $\Rightarrow \hat{\theta} \pm z_{\alpha/2} \sigma(\hat{\theta})$  je  $(1-\alpha)$ -CI  
 $\hookrightarrow z_{\alpha/2} := \Phi^{-1}(1 - \frac{\alpha}{2})$

Věta:  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ , neznám  $\sigma$ , chci  $\mu$   
 $\Rightarrow \bar{X}_n \pm \lambda_{\alpha/2} \frac{\hat{\Sigma}_n}{\sqrt{n}}$  je  $(1-\alpha)$ -CI  
 $\hookrightarrow \lambda_{\alpha/2} := \Psi_{m-1}^{-1}(1 - \frac{\alpha}{2})$

Bodové odhady ... odhadnu parametr  $\theta$

bias( $\hat{\theta}$ ) =  $E[\hat{\theta}] - \theta$  ...  $\hat{\theta}$  = statistika co ho odhadnuj  
 $\hookrightarrow$  nekramý  $\equiv$  bias = 0  
 $\hookrightarrow$  asympt. n.  $\equiv \lim_{n \rightarrow \infty} E\hat{\theta}_n = \theta$   
 $\hookrightarrow$  konzistentní  $\equiv \hat{\theta}_n \xrightarrow{P} \theta$   $\rightarrow$  ZVC:  $\bar{X}_n$  je konz.  $\mu$

$MSE(\hat{\theta}) := E[(\hat{\theta} - \theta)^2] = Var \hat{\theta} + bias(\hat{\theta})^2$

$\rightarrow \bar{X}_n$  ... nestr. & pro  $\mu$   
 $\rightarrow \hat{\Sigma}_n^2 := \frac{1}{n-1} \sum (X_i - \bar{X}_n)^2$  ... nestr. & pro  $\sigma^2$

Metoda momentů

$m_r := E[X^r]$  } polinóm rovnost  $\Rightarrow$  soustava rovnic  
 $\hat{m}_n := \frac{1}{n} \sum X_i^r$  }  $\hookrightarrow m_1 = EX, m_2 = \sigma^2 + \mu^2$  smit edet

Maximum Likelihood

$\rightarrow \max P[X_1=x_1 \& \dots \& X_n=x_n] \stackrel{mez.}{=} \prod_i P[X_i=x_i | \theta]$   
 $\Rightarrow L(\theta, \bar{x}) = \prod_i P[X_i=x_i] = \prod_i f_{X_i}(x_i), \ell(\theta, \bar{x}) = \log L$

Testování hypotéz

$H_0 \times H_1$

• vybrat statistický model:  $X \sim N(\mu, \sigma^2)$   
 • statistický test  $T = h(X_1, \dots, X_n)$  }  $\mathcal{W} \in \mathbb{R}$   
 • kritický obor:  $\mathcal{W} \subseteq \mathbb{R}$  }  $\Rightarrow$  zamítnutí  $H_0$   
 $\Rightarrow$  chyba 1. druhu  $\alpha = P[T \in \mathcal{W} | H_0]$   
 $\Rightarrow$  chyba 2. druhu  $\beta = P[T \notin \mathcal{W} | H_1]$   
 $\hookrightarrow$  malé  $\alpha \rightarrow$  slabý test - nezamítnutí hodně chyb  
 $\hookrightarrow 1 - \beta =$  síla testu  
 $\Rightarrow p$ -value = min  $\alpha$ , pro kterým bych  $H_0$  zamítl

Jednovýběrový test ...  $X_1, \dots, X_n \sim N(\mu, \sigma^2) \rightarrow H_0: \mu = \mu_0$

Dvouvýběrový test ...  $X_1, \dots, X_m \sim N(\mu_X, \sigma^2)$   
 $Y_1, \dots, Y_n \sim N(\mu_Y, \sigma^2) \rightarrow H_0: \mu_X = \mu_Y$

Párový test ...  $X_1, \dots, X_m \sim N(\mu_X, \sigma^2)$   
 $Y_1, \dots, Y_m \sim N(\mu_Y, \sigma^2) \rightarrow$  hyp.  $[\mu_X - \mu_Y] = 0$

$\hookrightarrow$  chci statistiku  $\bar{X}_n \Rightarrow$  normalizace

Z-test  $Z = \frac{\bar{X}_n - E\bar{X}_n}{\sigma/\sqrt{n}} \sim N(0,1) \Rightarrow \mathcal{W} = \{x \in \mathbb{R} | |x| > z_{\alpha/2}\}$

T-test  $T = \frac{\bar{X}_n - E\bar{X}_n}{\hat{\Sigma}_n/\sqrt{n}} \sim T(m-1) \Rightarrow \mathcal{W} = \{x \in \mathbb{R} | |x| > \lambda_{\alpha/2}\}$   
 $\hookrightarrow$  neznám  $\sigma \Rightarrow$  odhad  $\Psi_{m-1}^{-1}(1 - \frac{\alpha}{2})$

Testy dobré shody

$\rightarrow$  KATEGORICKÁ DATA  
 Observed:  $O_1, \dots, O_k$   
 Expected:  $E_1, \dots, E_k$   
 G-test:  $G = 2 \cdot \sum_i O_i \log \frac{O_i}{E_i}$   
 $\chi^2$ -test:  $\chi^2 = \sum_i \frac{(O_i - E_i)^2}{E_i}$   
 kritický obor:  $\mathcal{W} = \{x \in \mathbb{R} | x > \gamma\}$   
 $\hookrightarrow$  chci  $P[T > \gamma | H_0] = \alpha$

# Pravděpodobnost

Def: Pravděpodobnostní prostor je  $(\Omega, \mathcal{F}, P)$ , kde

- $\Omega$  ... množina el. jevi (křídne resp. číselná)
- $\mathcal{F} \subseteq \mathcal{P}(\Omega)$  ... množina jevi (jev = nastane jeden z těch el. jevi)  
 $\hookrightarrow \mathcal{F} = \mathcal{P}(\Omega)$  funguje dobře jen pro spočetné  $\Omega$

i)  $\emptyset, \Omega \in \mathcal{F}$

ii)  $A \in \mathcal{F} \Rightarrow A^c := \Omega \setminus A \in \mathcal{F}$

iii)  $A_1, A_2, \dots \in \mathcal{F} \Rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{F}$

•  $P: \mathcal{F} \rightarrow [0, 1]$  ... pravděpodobnost

i)  $P(\Omega) = 1$


ii)  $P(\bigcup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$  pro  $A_i \cap A_j = \emptyset$  → pro dvou disj. jevi

☞  $P(\emptyset) = 0$  ∴  $P(\bigcup_{i=1}^{\infty} \emptyset) = \sum_{i=1}^{\infty} P(\emptyset)$  ... jinak: něco  $\in [0, 1] = \infty$

$P(A_1 \cup A_2) = P(A_1) + P(A_2)$  pro  $A_1 \cap A_2 = \emptyset$  ( $A_3, A_4, \dots = \emptyset$ )

☞  $A_1, A_2 \in \mathcal{F} \Rightarrow A_1 \cup A_2 \in \mathcal{F}$  ∴  $A_3, A_4, \dots = \emptyset$


$\Rightarrow A_1 \cap A_2 \in \mathcal{F}$  ∴  $A_1 \cap A_2 = (A_1^c \cup A_2^c)^c$



Tvrzení: Necht  $(\Omega, \mathcal{F}, P)$  je p.p. a  $A, B \in \mathcal{F}$ . Potom

1)  $P(A) + P(A^c) = 1$

2)  $A \subseteq B \Rightarrow P(A) \leq P(B)$  &  $P(B \setminus A) = P(B) - P(A)$ .



3)  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$




4)  $P(\bigcup_{i=1}^{\infty} A_i) \leq \sum_{i=1}^{\infty} P(A_i)$  ... subaditivita

Důz:  
 1)  $\Omega = A \cup A^c \Rightarrow P(\Omega) = P(A \cup A^c) = P(A) + P(A^c)$

2)  $B = A \cup (B \setminus A) \Rightarrow P(B) = P(A) + P(B \setminus A)$  &  $P(B \setminus A) \geq 0$  ∴ to je jas.

3)  $A \cup B = A \cup (B \setminus (A \cap B)) \Rightarrow P(A \cup B) = P(A) + P(B \setminus (A \cap B)) = P(A) + P(B) - P(A \cap B)$

4)  $B_i \subseteq A_i$ :  $B_1 = A_1$ ,  $B_i = A_i \setminus \bigcup_{j < i} A_j \Rightarrow B_1, B_2, \dots$  jsou dvou disj.



$\Rightarrow$  ale  $\bigcup_{i=1}^{\infty} B_i = \bigcup_{i=1}^{\infty} A_i$

$B_i \subseteq A_i$

→ přesně přes

$\Rightarrow P(\bigcup A) = P(\bigcup B) = \sum P(B_i) \leq \sum P(A_i)$


princíp i. a l.

Příklady p.f.:

• klasický:  $\Omega$  konečná & uniformní  $P \Rightarrow P(A) = \frac{|A|}{|\Omega|}$

• diskrétní:  $\Omega$  spočetná

$$\mu: \Omega \rightarrow [0, 1], \quad \sum_{\omega \in \Omega} \mu(\omega) = 1, \quad P(A) = \sum_{\omega \in A} \mu(\omega)$$


• geometrický:  $\Omega \subseteq \mathbb{R}^d$  ...   $\subseteq \mathbb{R}^2$

$\mathcal{F} = \{A \in \mathcal{P}(\Omega) \mid \text{Vol}(A) \text{ je definovaný}\}$  ... rovinné tělíska a tělesa

$$P(A) = \frac{\text{Vol}(A)}{\text{Vol}(\Omega)}$$

• spojitý:  $\Omega \subseteq \mathbb{R}^d$  ...  $[0, 1] \subseteq \mathbb{R}$

$$f: \Omega \rightarrow [0, \infty), \quad \int_{\Omega} f = 1, \quad P(A) = \int_A f$$



$$f(x) = \frac{1}{2}x$$

$$\Omega = [0, 2]$$

$$\int_0^2 f(x) dx = 1 \quad \checkmark$$


$$\Rightarrow P([1, 2]) = \int_1^2 f(x) dx = \left. \frac{x^2}{4} \right|_1^2 = 0.75$$

Podmíněná pravděpodobnost

Def: Est jev  $A$  za podmínky, že nastal jev  $B$  je

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

Ukážka:



$$P(B) = \frac{1}{2}$$

$$P(1) = P(2) = P(3) = \frac{1}{10}$$

$$P(1|B) = \frac{P(1)}{P(B)} = \frac{\frac{1}{10}}{\frac{1}{2}} = \frac{1}{5}$$

$$P(2|B) = \frac{P(\emptyset)}{P(B)} = 0$$

$$P(3|B) = \frac{P(3 \cap B)}{P(B)} = \frac{1}{10}$$

Tvrzení: Necht' je  $(\Omega, \mathcal{F}, P)$  p.f.,  $B \in \mathcal{F}$  a  $P(B) > 0$ . Pro  $A \in \mathcal{F}$  definujeme  $Q(A) := P(A|B)$ . Tvrzíme, že  $(\Omega, \mathcal{F}, Q)$  je také p.f.

Dě: Funkce  $Q$  musí být pravděpodobnost, tedy musí splňovat

$$i) Q(\Omega) = 1 \quad \dots \quad Q(\Omega) = P(\Omega|B) = \frac{P(\Omega \cap B)}{P(B)} = 1 \quad \checkmark$$

$$ii) Q\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} Q(A_i), \quad A_i \cap A_j = \emptyset \quad \leftarrow \text{de-Morgan} \rightarrow \text{disj}$$

$$\begin{aligned} \rightarrow Q\left(\bigcup_{i=1}^{\infty} A_i\right) &= P\left(\bigcup_{i=1}^{\infty} A_i | B\right) = \frac{P\left(\left(\bigcup_{i=1}^{\infty} A_i\right) \cap B\right)}{P(B)} = \frac{1}{P(B)} \cdot P\left(\bigcup_{i=1}^{\infty} (A_i \cap B)\right) = \\ &= \frac{1}{P(B)} \cdot \sum_{i=1}^{\infty} P(A_i \cap B) = \sum_{i=1}^{\infty} P(A_i | B) = \sum_{i=1}^{\infty} Q(A_i). \quad \blacksquare \end{aligned}$$

Příklad:  $A_i \sim i$ -lá karta v balíčku 32 karet je ♥.

$$P(A_1 \cap A_2) = P(A_1) \cdot P(A_2 | A_1) = \frac{8}{32} \cdot \frac{7}{31}$$

↳ Kdybych sihle chtěl z definice, tak jsem si nepomohl  
 ⇒ vlastně to počítám v normálním p.f.

Věta (o zřetězeném podmínování): Necht'  $A_1, \dots, A_m \in \mathcal{F}$ ,  $P(A_1 \cap \dots \cap A_{m-1}) > 0$ .

$$P(A_1 \cap \dots \cap A_m) = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 \cap A_2) \cdot \dots \cdot P(A_m | A_1 \cap \dots \cap A_{m-1}).$$

Dě: indukci.

Def: Rozklad množiny  $\Omega$  je systém disj. množin  $B = \{B_1, B_2, \dots\}$  t.j.  $\rightarrow$  společně tvoří

$$\forall i: B_i \subseteq \Omega \quad \& \quad \bigcup B = \Omega$$

Věta (o rozkladu případů): Necht'  $B$  je rozklad  $\Omega$  a  $A \in \mathcal{F}$ . Potom platí

$$P(A) = \sum_i P(B_i) \cdot P(A|B_i), \quad \text{ kde pro } P(B_i) = 0 \text{ dodefinujeme } P(A|B_i) := 0.$$

Dě:  $A = (A \cap B_1) \cup (A \cap B_2) \cup (A \cap B_3) \cup \dots$  disj.



$$\Rightarrow P(A) = \sum_i P(A \cap B_i) = \sum_i P(B_i) \cdot P(A|B_i). \quad \blacksquare$$

Věta (Bayesova): Necht'  $B$  je rozklad  $\Omega$  a  $A \in \mathcal{F}$ . Platí

$$P(B_j | A) = \frac{P(B_j \cap A)}{P(A)} = \frac{P(B_j) \cdot P(A|B_j)}{\sum_i P(B_i) \cdot P(A|B_i)}$$

$$\rightarrow \text{speciálně } P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)}$$

Příklad: Gambler's ruin.

→ férová hra: vsadí \$1, a je 50% šance vyhrát \$1 zpět.

$$f(a) := P[\text{odejde s } \$N, \text{ když začal s } \$a] \quad 0 \leq a \leq N$$

$$A \sim f(a)$$

$B \sim$  výhra v 1. kole

$$\left. \begin{array}{l} A \sim f(a) \\ B \sim \text{výhra v 1. kole} \end{array} \right\} P(A) = P(B) \cdot P(A|B) + P(B^c) \cdot P(A|B^c)$$

→ probna v 1. kole


$$\Rightarrow f(a) = \frac{1}{2} \cdot f(a+1) + \frac{1}{2} \cdot f(a-1)$$

$$f(0) = 0$$

$$f(N) = 1$$

$$2f(a) = f(a+1) + f(a-1)$$

$$\Delta = f(a+1) - f(a) = f(a) - f(a-1)$$



$$\Rightarrow \underline{f(a) = \frac{a}{N}}$$

Příklad:

$a = n+1$  - bitové číslo

101...0 | 1

$b = n$  - bitové číslo

011...1 | 1

$$P[|a|_1 > |b|_1] = ? \quad \Rightarrow X := \text{počet, že ve } 2n\text{-bit číselch je stejný } \neq 1$$

→ poslední bit a je buď

✓ počet, že v prvních ních je víc

• 0  $\Rightarrow P[|a|_1 > |b|_1 | 0] = \frac{1-x}{2}$

• 1  $\Rightarrow P[|a|_1 > |b|_1 | 1] = x + \frac{1-x}{2}$  → stejně nebo v a víc

$$\Rightarrow P[|a|_1 > |b|_1] = \frac{1}{2} \cdot \frac{1-x}{2} + \frac{1}{2} \cdot \left(x + \frac{1-x}{2}\right) = \frac{1}{2} \cdot (x + 1 - x) = \frac{1}{2}$$

• Nezávislost jevi

Def: Jevy  $A, B \in \mathcal{F}$  jsou nezávislé,  $A \perp B \equiv P(A \cap B) = P(A) \cdot P(B)$

☉  $A \perp B \Leftrightarrow \frac{P(A \cap B)}{P(B)} = P(A) \Leftrightarrow P(A|B) = P(A)$

Def: Požad  $P(A|B) > P(A)$  ...  $A, B$  jsou pozitivně korelované  
 $P(A|B) < P(A)$  ...  $A, B$  jsou negativně korelované

Def: Necht  $I$  je indexová množina. Jevy  $\{A_i : i \in I\}$  jsou nezávislé  $\equiv$

$$\forall J \subseteq I : P\left(\bigcap_{j \in J} A_j\right) = \prod_{j \in J} P(A_j)$$

Def: Jevy  $A, B$  jsou nezávislé za podmínky C,  $A \perp_C B \equiv$

$$P(A \cap B | C) = P(A|C) \cdot P(B|C)$$



Teorem:  $A \perp B \Rightarrow A \perp B^c$  &  $A^c \perp B$

De:  $P(A \cap B^c) = P(A \setminus (A \cap B)) = P(A) - P(A) \cdot P(B) = P(A) \cdot (1 - P(B)) = P(A) \cdot P(B^c)$

$$A^c \perp B^c \quad \because A \perp B \Rightarrow A^c \perp B^c$$

## • Diskrétní náhodné veličiny

Def: Necht'  $(\Omega, \mathcal{F}, P)$  je p.f. Funkce  $X: \Omega \rightarrow \mathbb{R}$  je diskrétní n.v.  $\equiv$

1,  $\text{Im}(X)$  je nejvýše spočetný ... obor hodnot

2)  $\forall x \in \mathbb{R}: \{X=x\} := \{\omega \in \Omega \mid X(\omega) = x\} \in \mathcal{F} \rightarrow X^{-1}(x)$

$\hookrightarrow$  to chceme, abychom se mohli ptát na  $P[X=x]$

Poznámka: Náhodná veličina  $X$  určuje p.f.  $(\Omega', \mathcal{F}', \mu)$ , kde

$$\Omega' = \text{Im}(X), \quad \mathcal{F}' = \mathcal{P}(\Omega'), \quad \mu(x) = P[X=x]$$

$\rightarrow$  tento prostor, resp. fci  $\mu$ , nazýváme rozdělení / distribuce  $X$ .

Def: Pravděpodobnostní fce (probability mass function = pmf) d.n.v.  $X$

je  $p_X: \mathbb{R} \rightarrow [0,1]$ ,  $x \mapsto P[X=x]$

☀  $\sum_{x \in \text{Im} X} p_X(x) = 1 \quad \because \quad \Omega = \bigcup_{x \in \text{Im} X} \{X=x\}$

$\xrightarrow{\text{rozděl. } \Omega}$

$\Omega \quad \boxed{X=1 \mid X=2 \mid X=3 \mid \dots}$

$\xleftarrow{P}$   $\xrightarrow{P}$

## Bernoulliho rozdělení

$$X \sim \text{Ber}(p) \quad \dots \quad P[X=1] = p_X(1) = p$$
$$P[X=0] = p_X(0) = 1-p$$

## Indikátor jevu $A \in \mathcal{F}$

$$I_A(\omega) = \begin{cases} 1 & \dots \omega \in A \quad \dots A \text{ nastal} \\ 0 & \dots \omega \notin A \quad \dots A \text{ nenastal} \end{cases}$$

☀  $I_A \sim \text{Ber}(P(A))$

## Geometrické rozdělení

$X =$  na kolikátý pokus se poprvé něco povedlo (pokusy jsou nezávislé s  $p$ )

$$X \sim \text{Geom}(p)$$

$$p_X(1) = p$$
$$p_X(2) = (1-p)p$$
$$p_X(3) = (1-p)^2 p$$
$$\Rightarrow p_X(k) = \begin{cases} (1-p)^{k-1} p & , \text{ pro } k \in \mathbb{N}^+ \\ 0 & , \text{ jinak} \end{cases}$$

$\rightarrow$  ještě potřebujeme  $\sum_{x \in \text{Im} X} p_X(x) = 1$

$$\sum_{k=1}^{\infty} p_X(k) = \sum_{k=1}^{\infty} (1-p)^{k-1} \cdot p = p \cdot \sum_{k=0}^{\infty} (1-p)^k = p \cdot \frac{1}{1-(1-p)} = 1 \quad \checkmark$$

## Binomické rozdělení

$X = \#$  úspěchů při  $n$  nezávislých pokusech s pří  $p$

$$X \sim \text{Bin}(n, p), \quad p_X(k) = \binom{n}{k} \cdot p^k (1-p)^{n-k} \quad \Rightarrow \quad \sum_{k=0}^{\infty} p_X(k) = (p + (1-p))^n = 1$$

☀ Součet nez. bin. roz. je lin. rozdělení

$$X \sim \text{Bin}(n, p), \quad Y \sim \text{Bin}(m, p), \quad X \perp Y \quad \Rightarrow \quad Z = X + Y \sim \text{Bin}(n+m, p)$$

$$\begin{aligned} p_Z(k) &= P[X+Y=k] = \sum_{i=0}^k P[X=i \& Y=k-i] = \sum_{i=0}^k p_X(i) \cdot p_Y(k-i) \\ &= \sum_{i=0}^k \binom{n}{i} p^i (1-p)^{n-i} \binom{m}{k-i} p^{k-i} (1-p)^{m-k+i} = p^k (1-p)^{n+m-k} \underbrace{\sum_{i=0}^k \binom{n}{i} \binom{m}{k-i}}_{\binom{n+m}{k}} \end{aligned}$$

## Poissonovo rozdělení

→ aproximace bin. r. pro velká  $n$  a malou  $p$

$$X \sim \text{Pois}(\lambda) \quad \dots \quad p_X(k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad \lambda > 0$$

$$\hookrightarrow \sum_{k=0}^{\infty} p_X(k) = \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} = e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot e^{\lambda} = 1 \quad \checkmark$$

## ☀ $\text{Pois}(\lambda) \approx \text{Bin}(n, \frac{\lambda}{n})$

↳ necht'  $X \sim \text{Pois}(\lambda)$  a  $X_n \sim \text{Bin}(n, \frac{\lambda}{n}) \Rightarrow$  studíme  $\lim_{n \rightarrow \infty} p_{X_n}(k) = p_X(k)$

$$\begin{aligned} p_{X_n}(k) &= \binom{n}{k} \cdot \left(\frac{\lambda}{n}\right)^k \cdot \left(1 - \frac{\lambda}{n}\right)^{n-k} = \frac{n!}{k!} \cdot \frac{\lambda^k}{n^k} \cdot \left(1 - \frac{\lambda}{n}\right)^n \cdot \left(1 - \frac{\lambda}{n}\right)^{-k} \quad \begin{matrix} n \rightarrow \infty \\ k \in \mathbb{N}_0 \end{matrix} \\ &= \frac{\lambda^k}{k!} \left(1 - \frac{\lambda}{n}\right)^n \cdot \frac{n!}{n^k} \xrightarrow{1} \frac{\lambda^k}{k!} e^{-\lambda} = p_X(k) \quad \dots \quad \left(1 + \frac{\lambda}{n}\right)^n \rightarrow e^{\lambda} \end{aligned}$$



## • Střední hodnota

Def: Střední hodnota d.m.v.  $X$  je  $EX := \sum_{x \in \text{Im} X} x \cdot p_X(x)$ .

↳ požad řada nekonverguje absolutně, takže není definovaná

☀ Požad je  $X$  d.m.v. na diskrétním p.f. (tedy  $\Omega$  je nejvýše spočetná), takže

$$EX = \sum_{\omega \in \Omega} X(\omega) \cdot P(\{\omega\})$$

$$\text{Dr: } \sum_{\omega \in \Omega} X(\omega) P(\{\omega\}) = \sum_{x \in \text{Im} X} \sum_{\omega: X(\omega)=x} X(\omega) P(\{\omega\}) = \sum_{x \in \text{Im} X} x \sum_{\omega \in X^{-1}(x)} P(\{\omega\}) = \sum_{x \in \text{Im} X} x \cdot P[X=x]$$

Příklady:

①  $X \sim \text{Ber}(p) \Rightarrow EX = 1 \cdot p + 0 \cdot (1-p) = \underline{p}$

②  $X \sim \text{Bin}(n, p) \Rightarrow EX = \sum_{k=0}^n k \cdot \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=1}^n k \cdot \binom{n}{k} p^k (1-p)^{n-k} =$   
 $EX = \underline{np}$   
 $= n \sum_{k=1}^n \binom{n-1}{k-1} p^k (1-p)^{n-k} = n \sum_{k=0}^{n-1} \binom{n-1}{k} p^{k+1} (1-p)^{n-1-k}$   
 $= n \cdot p \sum_{k=0}^{n-1} \binom{n-1}{k} p^k (1-p)^{(n-1)-k} = n \cdot p \cdot (p + (1-p))^{n-1} = np$

Lemma o dělení:

③  $X \sim \text{Geom}(p) \Rightarrow EX = \sum_{k=1}^{\infty} k \cdot p_X(k) = \sum_{k=1}^{\infty} k \cdot (1-p)^{k-1} p = p \cdot \sum_{k=1}^{\infty} k (1-p)^{k-1}$   
 $\sum_{k=0}^{\infty} q^k = \frac{1}{1-q} \Rightarrow \frac{d}{dx} \sum_{k=0}^{\infty} q^k = \sum_{k=1}^{\infty} k q^{k-1} = \frac{1}{(1-q)^2} \quad \left| \quad = p \cdot \frac{1}{(1-(1-p))^2} = \underline{\underline{\frac{1}{p}}}$

## • Pravidlo nainho stohistika - PNS

☀ Požad je  $X$  d.m.v. a  $g: \mathbb{R} \rightarrow \mathbb{R}$ , potom je  $Y := g(X)$  také d.m.v.


Dr: Chceme  $Y$  d.m.v., tedy

1)  $Y: \Omega \rightarrow \mathbb{R}$  ✓

2)  $\text{Im}(Y)$  je nejvýše spočetný  $\because |\text{Im}(X \circ g)| \leq |\text{Im}(X)|$

3) pro  $\forall y \in \mathbb{R}: Y^{-1}(y) = \{Y=y\} \in \mathcal{F}$

$Y^{-1}(y) = \bigcup_{x \in \text{Im} X} X^{-1}(x) \quad \& \quad X^{-1}(x) \in \mathcal{F} \Rightarrow Y^{-1}(y) \in \mathcal{F}$



↳ spočetné sjednocení  $\hookrightarrow$  jeden z axiomů pravděpodobnosti

Věta (PNS): Požad  $X$  je d.m.v. a  $g: \mathbb{R} \rightarrow \mathbb{R}$ , potom

$$E[g(X)] = \sum_{x \in \text{Im} X} g(x) \cdot p_X(x)$$

$y$  je určeno jedinečně,  
 $\sum_x \sum_{y: g(x)=y} g(x) \cdot p_X(x) = \sum_x g(x) \cdot p_X(x)$

Dů: Označme  $Y := g(X)$ . Z definice

$$E[Y] = \sum_{y \in \text{Im} Y} y \cdot P[Y=y] = \sum_y y \cdot \sum_{x: g(x)=y} P[X=x] = \sum_y \sum_{x: g(x)=y} g(x) \cdot p_X(x)$$

→ jako v minulém díle:  $\{Y=y\} = Y^{-1}(y) = \bigcup_{x \in \text{Im} X} X^{-1}(x) = \bigcup_{\substack{x \in \text{Im} X \\ g(x)=y}} \{X=x\}$  disj.

Věta (vlastnosti E):  $X, Y$  jsou d.m.v.

①  $P[X \geq 0] = 1$  &  $EX = 0 \Rightarrow P[X=0] = 1$

②  $EX \geq a \Rightarrow P[X \geq a] > 0$

③  $E[aX+b] = aEX + b$

④  $E[X+Y] = EX + EY$  ... zatím pouze pro diskrétní p.p.

Dů: ①  $EX = \sum_x x \cdot p_X(x) = 0$ , všechny členy  $\geq 0 \Rightarrow$  všechny členy  $= 0$

②  $EX = \sum_x x \cdot p_X(x) \geq a$ . Kdyby  $P[X \geq a] = 0$ , tak  $\forall x \geq a: P(X=x) = 0$

$\Rightarrow$  tedy  $\sum_x x \cdot p_X(x) < \sum_x a \cdot p_X(x) = a \sum_x p_X(x) = a \Rightarrow a \leq \sum < a$   $\nabla$

③  $E[aX+b] = E[g(X)] = \sum_x (ax+b) \cdot p_X(x) = a \sum_x x \cdot p_X(x) + b \sum_x p_X(x) = aEX + b$

④  $E[X+Y] = \sum_{\omega \in \Omega} (X(\omega) + Y(\omega)) \cdot P(\{\omega\}) = \sum_{\omega} X(\omega) P(\omega) + \sum_{\omega} Y(\omega) P(\omega) = EX + EY$

Linearita střední hodnoty:  $E[\sum_i a_i X_i] = \sum_i a_i EX_i$

→ aplikace:  $X \sim \text{Bin}(n, p) \rightarrow EX = ?$  (vímé n.p)

$X = \#$  úspěchů v  $n$  pokusech  $\Rightarrow X_i =$  Indikátor, že  $i$ -tý pokus uspěl

$EX = \sum_{i=1}^n EX_i = n \cdot p$   $\hookrightarrow X_i \sim \text{Ber}(p) \Rightarrow EX_i = p$

Dů (podmíněná E): Necht' je  $X$  d.m.v.,  $B$  je v,  $P(B) > 0$ . Definujeme

$E[X|B] := \sum_{x \in \text{Im} X} x \cdot P[X=x|B]$  → opět požad. se absolutně konverguje

Věta (o celkové E): Necht' je  $B_1, B_2, \dots$  rozklad  $\Omega$  a  $X$  je d.m.v. Potom

$EX = \sum_i P(B_i) \cdot E[X|B_i]$

Dů:  $\sum_x x P[X=x] = \sum_x x \cdot \sum_i P(B_i) \cdot P[X=x|B_i] = \sum_i P(B_i) \cdot \sum_x x \cdot P[X=x|B_i]$

$\hookrightarrow$  věta o celkové p.p.  $E[X|B_i]$

## Príklady:

①  $X =$  celkové skóre pri házení kostkou, opožují, před padla 6

$$E X = P(\dots) \cdot E[X | \dots] + (1 - P(\dots)) \cdot E[X | \dots^c]$$

$$= \frac{1}{6} \cdot (6 + E X) + \frac{5}{6} \cdot 3 \quad \hookrightarrow \frac{1}{5} (1+2+3+4+5) = 3$$

$$= \frac{1}{6} E X + \frac{7}{2} \Rightarrow E X = \frac{42}{10} = \underline{\underline{4.2}}$$

②  $m$ -bit číslo,  $P(1) = p$

1234  
101100

$X =$  # podřetevců 101  $\Rightarrow E X = ?$

$A_i :=$  má  $i$ -té pozici ráčinná 101.  $\rightarrow P[A_i] = p(1-p)p = p^2(1-p)$

$$\rightarrow X = \sum_{i=1}^{m-2} I_{A_i} \Rightarrow E X = \sum_{i=1}^{m-2} E I_{A_i} = \underline{\underline{(m-2) \cdot p^2(1-p)}} \quad \Rightarrow E I_{A_i} = p^2(1-p)$$

③ Necht  $A$  je prv a  $I_A$  jeho indikátor. Před  $A = A_1 \cup A_2 \cup \dots \cup A_m$ , kde

$$1 - I_A = \prod_{i=1}^m (1 - I_{A_i}) \quad \dots \text{celkem obvious}$$

$$E[1 - I_A] = 1 - P(A) = E \left[ \prod_{i=1}^m (1 - I_{A_i}) \right]$$

$\hookrightarrow$  rozmásdit + line E  $\Rightarrow$  princíp i a celkem

Věta: Před je  $X$  d.m.v. a  $\text{Im}(X) \subseteq \mathbb{N}$ , potom

$$E X = \sum_{m=0}^{\infty} P[X > m] \rightarrow s(\lambda) := P[X > \lambda] \dots \text{survival function}$$

$$\text{Pr: } E X = 1 \cdot p_X(1) + 2 \cdot p_X(2) + 3 \cdot p_X(3) + \dots$$

$$= p_1 + p_2 + p_3 + p_4 + \dots = P(X > 0)$$

$$+ p_2 + p_3 + p_4 + \dots = P(X > 1)$$

$$+ p_3 + p_4 + \dots = P(X > 2)$$

$$+ p_4 + \dots = P(X > 3)$$

Príklad:  $X \sim \text{Geom}(p)$

$$E X = \sum_{m=0}^{\infty} P(X > m) = \sum_{m=0}^{\infty} (1-p)^m = \frac{1}{1-(1-p)} = \frac{1}{p}$$

Def: Rozptyl d.m.v.  $X$  je  $\text{var}(X) := \mathbb{E}[(X - \mathbb{E}X)^2]$

Směrodatná odchylka  $\sigma_X := \sqrt{\text{var}X}$

Variační koeficient  $\text{CV}_X := \frac{\sigma_X}{\mathbb{E}X}$  ... pouze pro  $\mathbb{E}X > 0$

Věta:  $\text{var}(X) = \mathbb{E}[X^2] - (\mathbb{E}X)^2 = \mathbb{E}[X(X-1)] + \mathbb{E}X - (\mathbb{E}X)^2$

Důk: Označme  $\mu := \mathbb{E}X$

$$\text{var}X = \mathbb{E}[(X - \mu)^2] = \mathbb{E}[X^2 - 2X\mu + \mu^2] = \mathbb{E}[X^2] - 2\mu\mathbb{E}X + \mu^2 = \mathbb{E}[X^2] - (\mathbb{E}X)^2$$

$$\Rightarrow \mathbb{E}[X(X-1)] = \mathbb{E}[X^2] - \mu \Rightarrow \mathbb{E}[X(X-1)] + \mu - (\mathbb{E}X)^2 = \mathbb{E}[X^2] - (\mathbb{E}X)^2 = \text{var}X$$

☉  $\text{var}(X) \geq 0 \Rightarrow \mathbb{E}[X^2] \geq (\mathbb{E}X)^2$

Důsledek: nerovnost mezi aritmetickým a kvadratickým průměrem

$$\frac{X_1^2 + X_2^2 + \dots + X_m^2}{m} \geq \left( \frac{X_1 + X_2 + \dots + X_m}{m} \right)^2 \Rightarrow \frac{1}{m} \sum_i X_i \leq \sqrt{\frac{1}{m} \sum_i X_i^2}$$

→ dožence platí i pro vážený průměr:  $\sum_i X_i w_i \leq \sqrt{\sum_i X_i^2 w_i}$ ,  $\sum_i w_i = 1$

☉  $\text{var}(X) = 0 \Leftrightarrow X$  je konstantní fce

Příklady:

①  $X \sim \text{Ber}(\mu) \Rightarrow \mathbb{E}X = \mu$

↳  $\text{Var}(X) = \mathbb{E}[(X - \mu)^2] = \mu \cdot (1 - \mu)^2 + (1 - \mu) \cdot \mu^2 = \underline{\mu(1 - \mu)}$

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

↓ zcela bonus

②  $X \sim \text{Bin}(n, \mu) \Rightarrow \mathbb{E}X = n \cdot \mu$

a, z definice: PNS:  $g(x) = (x - n\mu)^2 \Rightarrow \text{var}X = \sum_{k=0}^n (k - n\mu)^2 \binom{n}{k} \mu^k (1 - \mu)^{n-k}$

b,  $\text{var}X = \mathbb{E}[X(X-1)] + n\mu - (n\mu)^2$

$$\mathbb{E}[X(X-1)] \stackrel{\text{PNS}}{=} \sum_{k=0}^n k(k-1) \binom{n}{k} \mu^k (1 - \mu)^{n-k} = \sum_{k=2}^n (k-1) \underbrace{k \binom{n-1}{k-1}} \mu^k (1 - \mu)^{n-k}$$

$$= (n-1)n \sum_{k=2}^n \binom{n-2}{k-2} \mu^k (1 - \mu)^{n-k} = n(n-1)\mu^2 \sum_{k=0}^{n-2} \binom{n-2}{k} \mu^k (1 - \mu)^{n-2-k}$$

$$= n(n-1)\mu^2 \cdot (\mu + (1 - \mu))^{n-2} = n(n-1)\mu^2$$

$\Rightarrow \text{var}X = \mu^2 n(n-1) + \mu n - \mu^2 n^2 = \underline{\mu \cdot n \cdot (1 - \mu)}$  →  $n$ -krát víc než  $\text{Ber}(\mu)$

③  $X \sim \text{Pois}(\lambda)$

→ obdobně  $\mathbb{E}X = \text{Var}X = \lambda$

$\rightsquigarrow \text{Pois}(\lambda) \approx \text{Bin}(n, \frac{\lambda}{n})$

$\mathbb{E}X = \lambda = n \cdot \frac{\lambda}{n}$

$\text{Var}X = \lambda \approx \lambda \cdot (1 - \frac{\lambda}{n})$

④  $X \sim \text{Geom}(\mu) \Rightarrow \mathbb{E}X = \frac{1}{\mu}$

$\text{Var} X = \mathbb{E}[X^2] - (\mathbb{E}X)^2 = \mathbb{E}[X^2] - \frac{1}{\mu^2}$

$\Rightarrow B_1 := \text{1. pokus úspěch}$   
 $B_2 := B_1^c$  }  $\mathbb{E}[X^2] = P(B_1) \cdot \mathbb{E}[X^2 | B_1] + P(B_2) \cdot \mathbb{E}[X^2 | B_2] =$   
 $= \mu \cdot 1^2 + (1-\mu) \cdot \mathbb{E}[(1+X)^2] =$   
 $= \mu + (1-\mu) \cdot (1 + 2 \cdot \frac{1}{\mu} + \mathbb{E}[X^2])$

$\Rightarrow \mathbb{E}[X^2] (1 - (1-\mu)) = \mu + 1 - \mu + \frac{2(1-\mu)}{\mu} \Rightarrow \mathbb{E}[X^2] = \frac{2-\mu}{\mu^2}$

$\Rightarrow \text{Var}(X) = \frac{2-\mu}{\mu^2} - \frac{1}{\mu^2} = \frac{1-\mu}{\mu^2}$

⑤  $Y = aX + b$

$\Rightarrow \text{Var}(Y) = a^2 \text{Var}(X)$  } imunité vůči posunům

$\sigma(Y) = |a| \sigma_X$

$CV_Y = CV_X$ , pro  $a \geq 0 \Rightarrow CV$  je imunité vůči škálování

• Náhodné veličiny na stejném p.p.

Def: Pro d.m.v.  $X, Y$  definujeme sdrúženou společnou hmotnostní fci (joint pmf) jako

$p_{X,Y}(x,y) := P[X=x \ \& \ Y=y]$

Aby to byla p.st., což musí pro  $\forall x,y \in \mathbb{R}$ :  $\{X=x \ \& \ Y=y\} \in \mathcal{F}$

Ukázka:

X \ Y	0	1	2
0	1/4	1/6	1/12
1	1/6	1/4	1/12

$\rightarrow p_X(0) = P[X=0] = \frac{1}{4} + \frac{1}{6} + \frac{1}{12}$

$p_Y(2) = P[Y=2] = \frac{1}{12} + \frac{1}{12}$

Def: Rozdělení  $p_{X,Y}$  říkáme sdrúžené rozdělení. Rozdělení jednotlivých složek  $p_X$  a  $p_Y$  nazýváme marginální rozdělení

$p_X(x) = \sum_{y \in \text{Im} Y} p_{X,Y}(x,y)$

$p_Y(y) = \sum_{x \in \text{Im} X} p_{X,Y}(x,y)$

☞ z m. r. nelze odvodit sdrúžené r.

↑ přes disj. sjednocení

	0	1
0	1	0
1	0	1

a

	0	1
0	1/2	1/2
1	1/2	1/2

mají stejná marg. rozdělení

☞ jde to, včed jsou  $X, Y$  nezávislé

Věta: Pokud je  $(X, Y)$  d.m.vektor a  $g: \mathbb{R}^2 \rightarrow \mathbb{R}$ , potom je  $g(X, Y)$  d.m.v. a platí

$$f_Z(z) = P[g(X, Y) = z] = \sum_{x, y: g(x, y) = z} f_{X, Y}(x, y)$$

Důk: Zjevně je  $\{g(x, Y) = z\}$  disj. sjednocením množin  $\{X=x \text{ \& } Y=y\}$  pro dvojice, pro které  $g(x, y) = z$ . Navíc se stačí omezit na  $x \in \text{Im } X$  a  $y \in \text{Im } Y$ , takže to sjednocení je spočetné  $\Rightarrow$  lze použít axiom  $P(U) = \sum P$ . ■

### Nezávislost d.m.v.

Def:  $X, Y$  jsou nezávislé d.m.v.,  $X \perp Y \equiv \forall x, y \in \mathbb{R}: \{X=x\} \perp \{Y=y\}$

☉  $X \perp Y \Leftrightarrow \forall x, y: f_{X, Y}(x, y) = f_X(x) f_Y(y)$

Def:  $X_1, \dots, X_m$  jsou nezávislé  $\equiv$  pro  $\{X_1=x_1\}, \dots, \{X_m=x_m\}$  jsou nezávislé.

### Multinomialní rozdělení

Házíme  $n$ -krát kostkou ... fírovou  $\Rightarrow p_1 = p_2 = \dots = p_6 = \frac{1}{6}$

$$\left. \begin{array}{l} X_1 := \# \text{ jedniček} \sim \text{Bin}(n, p_1) \\ \vdots \\ X_m := \# \text{ šestek} \sim \text{Bin}(n, p_6) \end{array} \right\} (X_1, \dots, X_m) \sim \text{Mult}(n, p_1, \dots, p_6)$$

$$\rightarrow f_{X_1, \dots, X_m}(k_1, \dots, k_m) = \binom{n}{k_1, \dots, k_m} \cdot p_1^{k_1} \cdot p_2^{k_2} \cdot \dots \cdot p_m^{k_m}$$

Def: Multinomialní koeficient  $\binom{n}{k_1, \dots, k_m} := \frac{n!}{k_1! \cdot \dots \cdot k_m!}$ ,  $\sum_i k_i = n$

$\hookrightarrow$  intuice: # způsobů jak rozdělit  $n$  prvků do  $m$  množin o  $k_1, \dots, k_m$  prvků

Věta (konvoluční vzorec): Necht  $X, Y$  jsou d.m.v. a  $Z := X + Y$ . Potom platí

$$f_Z(z) = P[X + Y = z] = \sum_{x \in \text{Im } X} P[X=x \text{ \& } Y=z-x]$$

☉ pokud  $X \perp Y$ , potom  $f_Z(z) = \sum_x f_X(x) f_Y(z-x)$ .

Důk: Použijeme předchozí větu.

Věta (PNS pro vektor): Necht'  $(X, Y)$  je d.m. vektor a  $g: \mathbb{R}^2 \rightarrow \mathbb{R}$ . Potom platí

$$E[g(X, Y)] = \sum_{x, y} g(x, y) \cdot p_{X, Y}(x, y)$$

Dů: Označme  $Z := g(X, Y)$  podle věty z předchozí stránky

$$E Z = \sum_z z \cdot p_Z(z) = \sum_z z \cdot \sum_{x, y: g(x, y) = z} p_{X, Y}(x, y) = \sum_z \sum_{x, y: g(x, y) = z} z \cdot p_{X, Y}(x, y)$$

$$= \sum_{x, y} \sum_{z: g(x, y) = z} z \cdot p_{X, Y}(x, y) = \sum_{x, y} g(x, y) p_{X, Y}(x, y). \quad \blacksquare$$

→ doplnění jen diskrétní

Věta: Necht' jsou  $X, Y$  d.m.v. v libovolném p.f.,  $a, b \in \mathbb{R}$ . Potom

$$E[aX + bY] = aEX + bEY.$$

Dů: Použijeme PNS a  $g(x, y) := ax + by$ .

$$E[aX + bY] = \sum_{x, y} (ax + by) p_{X, Y}(x, y) = a \sum_{x, y} x p_{X, Y}(x, y) + b \sum_{x, y} y p_{X, Y}(x, y)$$

$$\rightsquigarrow \sum_{x, y} x p_{X, Y}(x, y) = \sum_x x \cdot \sum_y p_{X, Y}(x, y) = \sum_x x p_X(x) = EX \quad \blacksquare$$

Věta:  $X \perp Y \Rightarrow EXY = EX \cdot EY$ .

Dů: PNS pro funkci  $g(x, y) = xy$ :

$$E[XY] = \sum_{x, y} xy \cdot p_{X, Y}(x, y) = \sum_{x, y} x \cdot y \cdot p_X(x) p_Y(y) = \sum_x \sum_y x p_X(x) y p_Y(y)$$

$$= \sum_x x p_X(x) \cdot \sum_y y p_Y(y) = EX \cdot EY$$

### • Kovariance

Def: Pro n.v.  $X, Y$  definujeme jejich kovarianci jako

$$\text{cov}(X, Y) := E[(X - EX)(Y - EY)]$$

Tvrzení:  $\text{cov}(X, Y) = EXY - EX \cdot EY$  ... linearita střední hodnoty

☞  $X \perp Y \Rightarrow \text{cov}(X, Y) = 0$

Tvrzení: Vlastnosti kovariance:

1)  $\text{var}(X) = \text{cov}(X, X)$

2)  $\text{cov}(X, aY + bZ + c) = a \cdot \text{cov}(X, Y) + b \cdot \text{cov}(X, Z)$  ... linearita


Věta: Pro d.m.v.  $X, Y$  platí:

$$\text{var}(X+Y) = \text{var}(X) + \text{var}(Y) + 2 \cdot \text{cov}(X, Y)$$

Důkaz:  $\text{var}(X+Y) = E[(X+Y - E(X+Y))^2] = E[(X+Y - EX - EY)^2] =$   
 $= E[X^2 - 2XEY + (EY)^2] + E[Y^2 - 2YEX + (EX)^2] + E[2(XY - XEY - YEX + EXEY)]$   
 $= E[(X-EX)^2] + E[(Y-EY)^2] + 2 \cdot E[(X-EX)(Y-EY)]$  ▣


Důsledek:  $X \perp Y \Rightarrow \text{var}(X+Y) = \text{var}(X) + \text{var}(Y)$ .

Intuice:  $\text{cov}(X, Y) = E[(X-EX)(Y-EY)]$  ... označme  $r(x, y) := (x-EX)(y-EY)$



$x > EX \Rightarrow$  nejvyšší  $y > EY \Rightarrow r > 0$   
 $x < EX \Rightarrow$  nejnižší  $y < EY \Rightarrow r > 0$  }  $\text{cov}(X, Y) > 0$

$\Rightarrow$  velké  $x \Rightarrow$  velké  $y$  ... zvyšuje rozptyl součtu



$x > EX \Rightarrow$  nejnižší  $y < EY \Rightarrow r < 0$   
 $x < EX \Rightarrow$  nejvyšší  $y > EY \Rightarrow r < 0$  }  $\text{cov}(X, Y) < 0$

$\Rightarrow$  velké  $x \Rightarrow$  malé  $y$  ... snižuje rozptyl součtu

### • Korelace vs Kausalita

Def: Korelace m.v.  $X, Y$  je  $\rho(X, Y) := \frac{\text{cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$ .

$\odot -1 \leq \rho(X, Y) \leq 1$

Důkaz: Použijeme Cauchyho nerovnost, která říká, že  $|EXY| \leq \sqrt{E[X^2] \cdot E[Y^2]}$ ,  
 kde dosadíme  $X' := X - EX$  a  $Y' := Y - EY$ , z čehož  $|\text{cov}(X, Y)| \leq \sigma_X \sigma_Y$  ▣

**!** Korelace  $\not\Rightarrow$  kausalitu ... rádne' je, že  $\rho(X, Y) = \rho(Y, X)$

$\hookrightarrow$  navíc korelace je často způsobena nějakou společnou příčinou



## Spojité mhodn veliiny

Def: Nhodn veliina (obecn) na f.p.  $(\Omega, \mathcal{F}, P)$  je funkce  $X: \Omega \rightarrow \mathbb{R}$  t. r.  $\forall x \in \mathbb{R}: \{X \leq x\} \in \mathcal{F}$ .

Def: Pro n. v.  $X$  definujeme distribuci funkci (cumulative dist. f. CDF) jako  $F_X: \mathbb{R} \rightarrow [0, 1]$ ,  $x \rightarrow P[X \leq x]$

Veta: Necht  $X$  je n. v. Pak

①  $F_X$  je nelesajic

②  $\lim_{x \rightarrow \infty} F_X(x) = 1$

③  $\lim_{x \rightarrow -\infty} F_X(x) = 0$

④  $F_X$  je sprava spojita

R

①  $a < b \Rightarrow \{X \leq a\} \subseteq \{X \leq b\} \Rightarrow P[X \leq a] \leq P[X \leq b]$

②  $A_m = \{X \leq m\} \dots A_1 \subseteq A_2 \subseteq \dots$

$$\hookrightarrow \lim_{m \rightarrow \infty} P(A_m) = P\left(\bigcup_{m \in \mathbb{N}} A_m\right) = P(\Omega) = 1$$

③  $B_m = \{X \leq -m\} \dots B_1 \supseteq B_2 \supseteq \dots$

$$\hookrightarrow \lim_{m \rightarrow \infty} P(B_m) = P\left(\bigcap_{m \in \mathbb{N}} B_m\right) = P(\emptyset) = 0$$

④ Necht  $x \in \mathbb{R}$ . Chceme  $\lim_{\varepsilon \rightarrow 0^+} F_X(x + \varepsilon) = F_X(x)$

$$C_m := \left\{X \leq x + \frac{1}{m}\right\} \Rightarrow \lim_{\varepsilon \rightarrow 0^+} F_X(x + \varepsilon) = \lim_{m \rightarrow \infty} P(C_m) = P\left(\bigcap_{m \rightarrow \infty} C_m\right) = F_X(x)$$

Def: N. v.  $X$  je spojita  $\equiv \exists f_X: \mathbb{R} \rightarrow \mathbb{R}$  t. r.

$$F_X(x) = \int_{-\infty}^x f_X(t) dt \quad \dots f_X \text{ je hustota } X$$

☞  $\frac{d}{dx} F_X(x) = f_X(x) \Rightarrow F_X$  je spojita.

☞  $f_X \geq 0 \dots \because F_X$  je nelesajic

☞  $\int_{-\infty}^{\infty} f_X(t) dt = 1 \quad \because \lim_{m \rightarrow \infty} F_X(m) = 1$

$\nearrow$  pdf  
 $\hookrightarrow$  probability density function

Intuice:

$$F_x(x) \approx \frac{\# \text{ čísel} \leq x}{\# \text{ pozorů}} \dots \text{empiric CDF} = \text{ECDF}$$

$\Rightarrow F_x$  je něco jako limita ECDF

$\rightarrow f_x$  je něco jako limita histogramu těch pozorů

Věta: Pro s.m.v.  $X$  platí

①  $\forall x \in \mathbb{R}: P(X=x) = 0$

②  $P(a \leq X \leq b) = \int_a^b f_x(t) dt$

Lagrange

Dů: ①  $P(X=x) \leq P(x - \frac{1}{n} < X \leq x + \frac{1}{n}) = \int_{x-\frac{1}{n}}^{x+\frac{1}{n}} f(t) dt \xrightarrow{n \rightarrow \infty} \frac{2}{n} f(x) \rightarrow 0$

$\hookrightarrow$  je vidět pro omezení  $f$ , pro neomezení detaily rozeberáme

②  $\int_a^b f_x(t) dt = F_x(b) - F_x(a) = P[a < X \leq b] = P[a \leq X \leq b] - P[X=a] \rightarrow 0$

Def: Střední hodnota s.m.v.  $X$  je  $EX := \int_{-\infty}^{\infty} x f_x(x) dx$  (přesně to je dobrá def.)

Věta (PNS):  $E[g(x)] = \int_{-\infty}^{\infty} g(x) f_x(x) dx$

Def: Var( $X$ ) :=  $E[(X-\mu)^2]$ ,  $\mu := EX$


$\hookrightarrow$  vyjádřit:  $\int_{-\infty}^{\infty} (x-\mu)^2 f_x(x) dx$

Trvám:  $\text{Var}(X) = E[X^2] - (EX)^2$  ... díky linearity, kterou zatím nemáme

# Všechny spoj. rozdělení

## ① Uniformní

$$X \sim \text{Unif}(a, b)$$



$$F_x(x) = \begin{cases} 0 & , x < a \\ \frac{x-a}{b-a} & , x \in [a, b] \\ 1 & , x > b \end{cases}$$

$$f_x(x) = \begin{cases} \frac{1}{b-a} & , x \in [a, b] \\ 0 & , \text{jinak} \end{cases}$$

$$EX = \int_{-\infty}^{\infty} x f(x) dx = \int_{-\infty}^a 0 dx + \int_a^b x \frac{1}{b-a} dx + \int_b^{\infty} 0 dx = \int_a^b \frac{x}{b-a} dx = \frac{1}{2} \left[ \frac{x^2}{b-a} \right]_a^b = \frac{a+b}{2}$$

$$\text{Var} X = E[X^2] - (EX)^2 = \int_{-\infty}^{\infty} x^2 f(x) dx - \left(\frac{a+b}{2}\right)^2 = \dots = \frac{(b-a)^2}{12}$$


## ② Exponenciální ... období geometrického

$$X \sim \text{Exp}(\lambda) \quad \lambda > 0 \quad F_x(x) = \begin{cases} 1 - e^{-\lambda x} & , x > 0 \\ 0 & , x \leq 0 \end{cases}$$

$$\Rightarrow f'_x(x) = F' = \lambda e^{-\lambda x}$$

$$EX = \int_0^{\infty} x \lambda e^{-\lambda x} dx = \dots = \frac{1}{\lambda}$$

$$\text{Var} X = \int_0^{\infty} x^2 \lambda e^{-\lambda x} dx - \frac{1}{\lambda^2} = \dots = \frac{1}{\lambda^2}$$



☞ Nemá paměť:  $P[X > \Delta + \Delta | X \geq \Delta] = P[X > \Delta]$


## ③ Standardní normální

hustota:  $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$

$$X \sim N(0, 1) \quad \rightarrow EX = 0$$

distribuce:  $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$

$$\rightarrow \text{Var} X = 1$$



↳ &  $\varphi(x)$  se dá dojit aproxiací Bin pomocí Stirlinga

## ④ Obecné normální

$$Z \sim N(0, 1)$$

↳ shift = střed

$$X \sim N(\mu, \sigma^2) \equiv X = \mu + \sigma \cdot Z$$

$$EX = \mu$$

$$\text{Var} X = \sigma^2$$

↳ rozložení

$$f_x(x) = \frac{1}{\sigma} \varphi\left(\frac{x-\mu}{\sigma}\right)$$

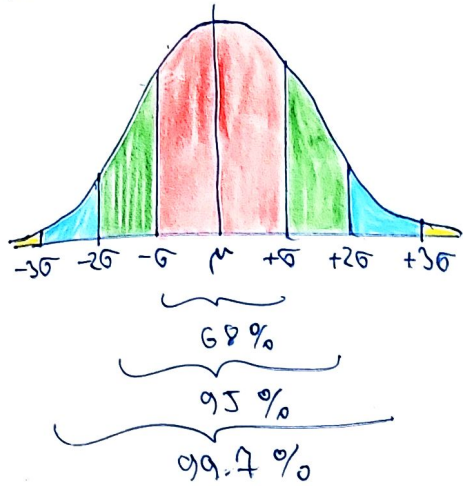
$$F_x(x) = \int_{-\infty}^x \frac{1}{\sigma} \varphi\left(\frac{t-\mu}{\sigma}\right) dt = \int_{-\infty}^{\frac{x-\mu}{\sigma}} \varphi(u) du = \Phi\left(\frac{x-\mu}{\sigma}\right)$$

Věta (odolnost vůči součtu):  $X_1, \dots, X_n$  jsou nez. n. v.  $X_i \sim N(\mu_i, \sigma_i^2)$

$$\Rightarrow X_1 + \dots + X_n \sim N(\mu, \sigma^2) \quad , \quad \begin{aligned} \mu &= \mu_1 + \dots + \mu_n \\ \sigma^2 &= \sigma_1^2 + \dots + \sigma_n^2 \end{aligned}$$

# Pravidlo 3σ

68-95-99.7 rule



$$P(\mu - \sigma < X < \mu + \sigma) = \Phi(1) - \Phi(-1) \approx 0.68$$


$$P(\mu - 2\sigma < X < \mu + 2\sigma) = \Phi(2) - \Phi(-2) \approx 0.95$$

$$P(\mu - 3\sigma < X < \mu + 3\sigma) = \Phi(3) - \Phi(-3) \approx 0.997$$

## 5) Cauchyho rozdělení

$$f_x(x) = \frac{1}{\pi(1+x^2)}$$

$$F_x(x) = \int_{-\infty}^x f_x = \frac{1}{\pi} \arctg x + \frac{1}{2}$$



→ vypadá podobně jako  $N(0,1)$

! střední hodnota neexistuje

$$EX = \int_{-\infty}^{\infty} x f_x(x) dx = \int_{-\infty}^0 x f_x + \int_0^{\infty} x f_x = \dots = \infty - \infty$$

$$\hookrightarrow \int_0^{\infty} x f_x = \frac{1}{\pi} \int_0^{\infty} \frac{x}{1+x^2} dx = \left| \begin{matrix} u=1+x^2 \\ du=2x dx \end{matrix} \right| = \frac{1}{2\pi} \int_1^{\infty} \frac{dx}{u} = \frac{1}{2\pi} \ln|u| \Big|_1^{\infty} = \infty$$

→ k čemu je dobré?




↖ Cauchyho rozdělení

## 6) Paretovo rozdělení

$$F_x(x) = \begin{cases} 1 - \left(\frac{x_0}{x}\right)^\alpha, & x \geq x_0 \\ 0, & x < x_0 \end{cases}$$

$\alpha, x_0 > 0$

$$f_x(x) = \begin{cases} \frac{\alpha}{x} \cdot \left(\frac{x_0}{x}\right)^\alpha, & x \geq x_0 \\ 0, & x < x_0 \end{cases}$$




☀  $F_x$  roste k 1 mnohem pomaleji než  $\exp \Rightarrow$  long tail = dlouhý chvost

$$EX = x_0 \frac{\alpha}{\alpha-1}$$

## • Kvantilová fce

Def: Pro n.v.  $X$  definujeme kvantilovou fci  $Q_x: [0,1] \rightarrow \mathbb{R}$  jako

$$Q_x(p) := \min \{x \in \mathbb{R} \mid p \leq F_x(x)\}$$



☞ Pro spojitou  $X$  je  $Q_x(p) = F_x^{-1}(p)$

☞ Pro  $\forall x \in \mathbb{R}$ :  $Q_x(p) \leq x \Leftrightarrow p \leq F_x(x) = P[X \leq x]$

Def: Medián je hodnota  $m := Q_x(\frac{1}{2})$

☞ Pro spojitou n.v.  $X$  je nejmenší reálné číslo, že

$$P[X \leq m] \geq \frac{1}{2} \text{ a } P[X > m] \leq \frac{1}{2}$$

→ pro d.n.v. může být několik hodnot vic

Def: První kvantil je hodnota  $q := Q_x(\frac{1}{4})$  ... 1. číselná hodnota  $\leq q$


Desátý percentil je  $Q_x(10/100)$  ... hodnota  $>$  než 10% hodnot ...

## • Náhodné vektory

Def: Pro n.v.  $X, Y$  na p.f.  $(\Omega, \mathcal{F}, P)$  definujeme sdruženou distribuční fci → joint cdf

$$F_{X,Y}: \mathbb{R}^2 \rightarrow [0,1], \quad F(x,y) = P[X \leq x \text{ \& } Y \leq y]$$

Věta (pro obdélník):



$$P[(X,Y) \in A] = P[X \in (a,b) \text{ \& } Y \in (c,d)]$$

$$F := F_{X,Y}$$

$$= F(b,d) - F(a,d) - F(b,c) + F(a,c)$$

Pro hustotu:

$$P[(X,Y) \in S] = \int_S f_{X,Y}(x,y) dx dy$$

$$f_{X,Y}(x,y) = \frac{\partial^2 F_{X,Y}}{\partial x \partial y}(x,y)$$

Marginalní hustota

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

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

Věta (PNS): Pro střední hodnotu funkce dvojn. n. v. platí

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

Důsledek (linearita E)  $\mathbb{E}[aX + bY + c] = a\mathbb{E}X + b\mathbb{E}Y + c$

Nezávislost

Def: Náhodné vel.  $X, Y$  jsou nezávislé,  $X \perp Y \equiv$

$$\forall x, y \in \mathbb{R} : \{X \leq x\} \perp \{Y \leq y\}$$

☞  $X \perp Y \Leftrightarrow F_{x, y}(x, y) = F_x(x) \cdot F_y(y)$ .


Věta:  $X \perp Y \Leftrightarrow f_{x, y}(x, y) = f_x(x) \cdot f_y(y)$ .

Věta (konvoluce): Nechtí  $X, Y$  jsou nezávislé spojité n. v. Pak  $Z := X + Y$  je také s. n. v. a platí

$$f_z(z) = \int_{-\infty}^{\infty} f_x(x) f_y(z-x) dx$$

Příklady:

①  $f_{x, y}(x, y) = \begin{cases} e^{-x-y}, & x, y > 0 \\ 0, & \text{jinak} \end{cases} \rightarrow P(X+Y \leq 1) = ?$



$$P(X+Y \leq 1) = \int_A \int_A f_{x, y}(x, y) dx dy = \int_0^{1-x} \int_0^{1-x} e^{-x-y} dy dx = \dots = \frac{e-2}{e}$$

②  $X, Y \sim N(0, 1) \Rightarrow Z := X + Y \sim ?$

$$\begin{aligned} f_z(z) &= \int_{-\infty}^{\infty} f_x(x) f_y(z-x) dx = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-x)^2}{2}} dx = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-x^2 - \frac{z^2}{2} + xz} dx \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-(x-\frac{z}{2})^2} e^{-\frac{z^2}{4}} dx = \frac{e^{-\frac{z^2}{4}}}{2\pi} \int_{-\infty}^{\infty} e^{-(x-\frac{z}{2})^2} dx = \\ &= \frac{e^{-\frac{z^2}{4}}}{2\pi} \int_{-\infty}^{\infty} e^{-u^2} du = \frac{1}{2\sqrt{\pi}} e^{-\frac{z^2}{4}} \Rightarrow \sigma = 2 \Rightarrow Z \sim N(0, 2) \end{aligned}$$

$x \sim N(0, \sigma^2) \dots f_x = \frac{1}{\sigma} \varphi\left(\frac{x}{\sigma}\right) = \frac{1}{\sigma} \cdot \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{1}{2} \cdot \left(\frac{x}{\sigma}\right)^2}$

• Kvirozměrné std. norm. rozdělení

$$Z_1, \dots, Z_m \rightarrow Z_i \sim N(0, 1) \Rightarrow f_{Z_i}(t) = \mathcal{L}(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}}$$

$\hookrightarrow Z := (Z_1, \dots, Z_m)$   $\hookrightarrow$  nezávislé  $\Rightarrow f_{X,Y} = f_X \cdot f_Y$

$$f_Z(t_1, \dots, t_m) = \prod_{i=1}^m f_{Z_i}(t_i) = (\sqrt{2\pi})^{-m} e^{-\frac{t_1^2 + \dots + t_m^2}{2}} = \underline{\underline{(\sqrt{2\pi})^{-m} \cdot e^{-\frac{\|\vec{t}\|^2}{2}}}}$$

$\Rightarrow f_Z$  záleží pouze na  $\|\vec{t}\|$ , tedy rozdělení od počátku

$\hookrightarrow$  je to radiálně symetrická funkce

$\rightarrow$  počet  $n=2$  (2 dimenze), takže  $f_Z$  je Bell-curve

$\Rightarrow$  díky této symetrii dávná  $X := \frac{Z}{\|Z\|}$   
unif. náhodný bod na jednotkové sféře v  $\mathbb{R}^m$

• Podmínování

Def:  $X$  je n.v. na  $(\Omega, \mathcal{F}, P)$ ,  $B \in \mathcal{F}$  a  $P(B) > 0$ . Definujeme

$$F_{X|B}(x) := P[X \leq x | B]$$

$\rightarrow$  k tomu přísluší  $f_{X|B}$ .

Věta (o rozkladu hustoty):  $X$  je s.m.v. a  $B_1, B_2, \dots$  je rozklad  $\Omega$ . Platí

$$F_X(x) = \sum_i P(B_i) \cdot F_{X|B_i}(x)$$

$$f_X(x) = \sum_i P(B_i) \cdot f_{X|B_i}(x)$$

Důz:  $F_X \dots$  věta o úplné pasti pro  $A = \{X \leq x\}$   
 $f_X \dots$  zderivujme  $F_X$

Def:  $E[X|B] := \int_{-\infty}^{\infty} x f_{X|B}(x) dx$

Věta: Pokud je  $B_1, B_2, \dots$  rozklad  $\Omega$ , takže

$$EX = \sum_i P(B_i) E[X|B_i]$$

## Nerovnosti

Příklad: Může být 99% lidí starších než průměr?

↳ Ano... 1 člověk ... 1 rok } průměr < 20  
99 lidí ... 20 let

Může být 51% lidí starších než 1x průměr? → NE!

Věta (Markovova ner.) Necht' n.v.  $X$  splňuje  $X \geq 0$ ,  $a \in \mathbb{R}$ . Pak

$$P[X \geq a] \leq \frac{EX}{a}$$

Důsledek:  $P[X \geq b \cdot EX] \leq \frac{1}{b}$  ... volbou  $a := b \cdot EX$

Dů:  $EX = P[X \geq a] \cdot E[X | X \geq a] + P[X < a] \cdot E[X | X < a]$

$$\geq P[X \geq a] \cdot E[X | X \geq a] \geq P[X \geq a] \cdot a \quad \blacksquare$$



Věta (Čebyševova ner.) Necht'  $X$  má  $\mu := EX$  a  $\sigma^2 := \text{Var}(X)$ ,  $\lambda > 0$ . Pak

$$P[|X - \mu| \geq \lambda \cdot \sigma] \leq \frac{1}{\lambda^2}$$

Dů:  $|X - \mu| \geq \lambda \cdot \sigma \stackrel{\Rightarrow \geq 0}{\Leftrightarrow} (X - \mu)^2 \geq \lambda^2 \sigma^2 \Rightarrow Y := (X - \mu)^2 \Rightarrow EY = \sigma^2$

$$\Rightarrow P[\dots] = P[Y \geq \lambda^2 \sigma^2] = P[Y \geq \lambda^2 EY] \leq \frac{1}{\lambda^2} \dots \text{Markov.} \quad \blacksquare$$

Odhady chvostů = tail estimates



Věta (Chernoffova ner.): Necht'  $X_i = \begin{cases} +1, & \text{přt} = 50\% \\ -1, & \text{přt} = 50\% \end{cases}$ .  $X := \sum_{i=1}^n X_i$ ,  $\lambda > 0$

$$P[X \leq -\lambda \cdot \sigma_x] = P[X \geq \lambda \cdot \sigma_x] \leq e^{-\frac{\lambda^2}{2}}, \quad \sigma_x^2 = n \Rightarrow \sigma = \sqrt{n}$$

↳ Čebyšev je kvadratický odhad, takže je exponenciální



## • Zákonny velkých čísel

Def: Výběrový průměr (sample mean) n.v.  $X_1, \dots, X_n$  je  $\bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i$ .

Věta (silný ZVČ): Necht'  $X_1, X_2, \dots$  jsou stejně rozdělené nezávislé n.v. se  $\mathbb{E}X_i = \mu$  a  $\text{Var} X_i = \sigma^2$ . Pak platí

$$P\left[\lim_{n \rightarrow \infty} \bar{X}_n = \mu\right] = 1 \quad \dots \quad \lim_{n \rightarrow \infty} \bar{X}_n = \mu \text{ skoro jistě}$$

Aplikace: Monte-Carlo integrování


↳ chcí spočítat  $I := \int_{\bar{x} \in S} g(\bar{x}) d\bar{x}$ ,  $S \subseteq \mathbb{R}^d$

↳ objem  $S$  ...  $V := \text{vol}(S) = \int_S d\bar{x}$

$\Rightarrow \bar{X}_1, \dots, \bar{X}_n$  jsou samplý  $\in S \Rightarrow I \approx Q_n = V \cdot \frac{1}{n} \sum_{i=1}^n f(\bar{X}_i)$

Př: Odhad obsahu kruhu

$$g(x, y) := \begin{cases} 1, & x^2 + y^2 \leq 1 \\ 0, & \text{jinak} \end{cases}$$



$S = \text{čtverec}$

$$\Rightarrow V = 4, \quad \frac{1}{n} \sum_{i=1}^n f(\bar{X}_i) = \frac{\# \text{ bodů v kruhu}}{\# \text{ bodů uvnitř}}$$

Věta (slabý ZVČ): Necht'  $X_1, X_2, \dots$  jsou stejně rozdělené nezávislé n.v. se  $\mathbb{E}X_i = \mu$  a  $\text{Var} X_i = \sigma^2$ . Pak pro  $\forall \varepsilon > 0$  platí

$$\lim_{n \rightarrow \infty} P[|\bar{X}_n - \mu| > \varepsilon] = 0, \quad \text{píšeme } \bar{X}_n \xrightarrow{P} \mu.$$

$\Rightarrow$  Říkáme, že posloupnost  $\bar{X}_n$  konverguje k  $\mu$  v pravděpodobnosti.

Důk:

☀  $X_1, \dots, X_n$  stejné r.  $\Rightarrow \mathbb{E} \bar{X}_n = \frac{1}{n} (\mathbb{E}X_1 + \dots + \mathbb{E}X_n) = \mu$

↳ pro Var:  $\text{var}(\bar{X}_n) = \frac{1}{n^2} \text{var}(\sum_i X_i) \xrightarrow{\text{nez.}} \frac{1}{n^2} (\text{var} X_1 + \dots + \text{var} X_n) = \frac{\sigma^2}{n}$

$\Rightarrow$  chceme použít Čebyševovu n.  $P[|X - \mu| > 1\sigma] \leq \frac{1}{2}$

$$\hookrightarrow \sigma_{\bar{X}_n} = \frac{\sigma}{\sqrt{n}} \Rightarrow 1 := \frac{\varepsilon \sqrt{n}}{\sigma}$$

$$\Rightarrow P[|\bar{X}_n - \mu| > 1 \cdot \frac{\sigma}{\sqrt{n}}] = P[|\bar{X}_n - \mu| > \varepsilon] \leq \frac{\sigma^2}{n \varepsilon^2} \rightarrow 0. \quad \blacksquare$$

## Centrální limitní věta

Věta: Necht'  $X_1, X_2, \dots$  jsou stejně rozdělené nezávislé n.v.  
se  $EX_i = \mu$  a  $\text{Var} X_i = \sigma^2$ . Označme

$$Y_m := \frac{\bar{X}_m - \mu}{\sigma/\sqrt{m}} = \frac{X_1 + \dots + X_m - m\mu}{\sqrt{m}\sigma}, \quad F_m := \text{distr. fce } Y_m$$

Potom  $\forall x \in \mathbb{R}$ :  $\lim_{m \rightarrow \infty} F_m(x) = \Phi(x)$ , píšeme  $Y_m \xrightarrow{d} N(0,1)$  a říkáme, že posloupnost  $Y_m$  konverguje k  $N(0,1)$  rozdílení.

Intuice:

$$\left. \begin{aligned} \textcircled{1} \quad EY_m &= m \cdot \frac{E\bar{X}_m - \mu}{\sqrt{m}\sigma} = m \cdot \frac{0}{\sqrt{m}\sigma} = 0 \\ \text{Var } Y_m &= \left(\frac{\sqrt{m}}{\sigma}\right)^2 \cdot \text{Var} \bar{X}_m = \frac{m}{\sigma^2} \cdot \frac{\sigma^2}{m} = 1 \end{aligned} \right\} Y_m \text{ „má šanci“ být } N(0,1)$$

$\textcircled{2}$  pokud  $X_i \sim N(\mu, \sigma^2)$ , tak (odkročíme níže součet) bude  $Y_m$  také normální.

$\hookrightarrow$  díky  $\textcircled{1}$  bude  $Y_m \sim N(0,1)$

$\Rightarrow$  pokud (LV platí pro nějaké rozdělení, tak jediné  $N(0,1)$ ).

Příklad: výťah má max. nosnost 1000 kg.

$\hookrightarrow$  nastoupí 13 osob,  $EX_m = 75 = \mu$ ,  $\sigma_x = 10$   
 $\Delta$  hodnotnostmi  $X_1, \dots, X_{13}$

$$\Rightarrow P(X_1 + \dots + X_{13} > 1000) = ? \quad \Rightarrow S_{13} := X_1 + \dots + X_{13}$$

$$\hookrightarrow Y_{13} := \frac{S_{13} - 13 \cdot 75}{10\sqrt{13}} \quad \dots \quad S_D > 1000 \Leftrightarrow Y_m > \frac{1000 - 13 \cdot 75}{10\sqrt{13}} \approx 0.69$$

$$\text{CLV: } Y_{13} \approx N(0,1) \Rightarrow P(S_D > 1000) \approx P(Y_m > 0.7) = 1 - P(Y_m \leq 0.7) = 1 - \Phi(0.7)$$

# STATISTIKA

1) Explorační analýza ... přehledné znázornění nějakých dat

2) Konfirmační analýza ... matematická disciplína

↳ snažíme se z dat zjistit nějaké skryté skutečnosti  
a odhalit nepravdy způsobené náhodným kolísáním dat

→ základ: jak vybírat z dané populace objekty, co budeme měřit?  
a) uniformně náhodně bez vracení  
b) uniformně náhodně s vracením → lépe se analyzuje

Def: Posloupanost nez. n.v.  $X_1, \dots, X_n$  se stejnou distribuční funkcí  $F$  je náhodný výběr s rozsahem  $n$ . Píšeme  $X_1, \dots, X_n \sim F$ .

↳ naměřená data  $x_1, \dots, x_n =$  realizace,  $x_i = X(\omega)$ .

↳ na základě realizace se snažíme určit  $F =$  model

① Neparametrický model ... nic o  $F$  nepředpokládáme  
↳ dost dobře nejde

② Parametrický model ...  $F$  je z nějaké množiny  $\{F_\theta \mid \theta \in \Theta\}$

$\text{Exp}(\lambda) \dots \theta = \lambda \quad \Theta = \mathbb{R}^+$

$U(a, b) \dots \theta = (a, b) \quad \Theta = \mathbb{R}^2$

$U(0, b) \dots \theta = b \quad \Theta = \mathbb{R}$

$N(\mu, \sigma^2) \dots \theta = (\mu, \sigma) \quad \Theta = \mathbb{R} \times \mathbb{R}^+$

↓  
možné světy

Def: Statistika je libovolná fce náhodného výběru  $T = T(X_1, \dots, X_n)$ .

↳ také to je n.v., ale svoji náhodnost čerpá pouze z  $X_1, \dots, X_n$

⇒ výběrový průměr, medián, maximum, ...

Příklad:  $X_1, \dots, X_n$  doby běhu programu  $\Rightarrow \mu = P[X > 100 \text{ ms}] = ?$

1)  $\hat{\mu} = \frac{\#i: X_i > 100 \text{ ms}}{n}$  ...  $x_1, \dots, x_n =$  naměřená data

2)  $X \sim N(\mu, \sigma^2) \Rightarrow P(X > 100) = 1 - P(X \leq 100) = 1 - \Phi\left(\frac{100 - \mu}{\sigma}\right)$

↳ známe  $\mu, \sigma \Rightarrow$  odhad  $\xrightarrow{\text{rozdílnostní rozdělení}}$

$\hat{\mu} = \bar{x}_n \quad \hat{\sigma}^2 = s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$  ... výběrový rozptyl

## • Bodové odhady

$\hat{\theta}$  ... odhad parametrem  $\theta$   $\rightarrow$  estimator

$\hookrightarrow$  náhodná v. závislá na naměřených datech  $\Rightarrow$  statistika

Def: Bias (vychýlení) odhadu  $\theta$  je  $E[\hat{\theta} - \theta] = E[\hat{\theta}] - \theta$


Def: Pro náhodný výběr  $X_1, \dots, X_n \sim F_\theta$  je bodový odhad  $\hat{\theta}_n$

1) nestranný  $\equiv E\hat{\theta}_n = \theta$  ... bias = 0

2) asymptoticky nestranný  $\equiv \lim_{n \rightarrow \infty} E\hat{\theta}_n = \theta$  ... bias  $\rightarrow 0$

3) konzistentní  $\equiv \hat{\theta}_n \xrightarrow{P} \theta$ , neboli  
 $\forall \epsilon > 0 : P[|\hat{\theta}_n - \theta| > \epsilon] \rightarrow 0. \Rightarrow$  malý rozptyl odhad měříte čím  
pořád blíž

☀ ZVC říká, že  $\bar{X}_n$  je konzistentní odhad  $EX$



Def: Střední kvadratická odchylka  $MSE(\hat{\theta}) := E[(\hat{\theta} - \theta)^2]$ .

Věta:  $MSE(\hat{\theta}) = \text{Var}(\hat{\theta}) + \text{bias}(\hat{\theta})^2$

Dů:  $\text{Var}(\hat{\theta}) = \text{Var}(\hat{\theta} - \theta) = E[(\hat{\theta} - \theta)^2] - E[(\hat{\theta} - \theta)]^2 = MSE(\hat{\theta}) - \text{bias}(\hat{\theta})^2$

Věta: Máme náhodný výběr  $X_1, \dots, X_n$ . Platí

①  $\bar{X}_n := \frac{1}{n} \sum_i X_i$  ... nestranný & konzistentní odhad  $\mu$

$\hookrightarrow$  x. mean()  $\rightarrow$  numpy

②  $\bar{S}_m^2 := \frac{1}{m} \sum_i (X_i - \bar{X}_m)^2$  ... asym. nestr. & konz. odhad  $\sigma^2$

$\hookrightarrow$  x. var (ddof = 0)

③  $\hat{S}_m^2 := \frac{1}{m-1} \sum_i (X_i - \bar{X}_m)^2$  ... nestranný & konz. odhad  $\sigma^2$

$\hookrightarrow$  x. var (ddof = 1)

výběrový rozptyl

Dů: ①  $E\bar{X}_n = \mu$  z linearitou, konzistence ze ZVC

② } konzistenci vynecháme, nestrannost  $\hat{S}_m^2$  je na druhé straně

③ }  $\rightarrow$  proč se tam objeví  $n-1$ ?  $\rightarrow$

Pr: Kolik je  $E\left[\sum_i (X_i - \bar{X}_m)^2\right]$  ?

$m \cdot \bar{X}_m$   
↑

$$E[\dots] = E\left[\sum_i (X_i^2 - 2X_i \bar{X}_m + \bar{X}_m^2)\right] = E\left[\sum_i X_i^2 - 2\bar{X}_m \sum_i X_i + m \cdot \bar{X}_m^2\right]$$

→ vyvíjej, že  $X_1, \dots, X_m \sim F_\theta$  ... stejná distr.

$$= m \cdot E X_i^2 - m E \bar{X}_m^2$$

→ vyvíjej  $\text{Var} X = E[X^2] - (EX)^2 \Rightarrow E X^2 = \text{Var} X + (EX)^2 = \sigma^2 + \mu^2$

$$= m(\sigma^2 + \mu^2) - m\left(\frac{\sigma^2}{m} + \mu^2\right) = (m-1)\sigma^2$$

nezavislost

$$\text{Var} X_m = \frac{1}{m^2} \text{Var}(X_1 + \dots + X_m) = \frac{1}{m^2} m \cdot \sigma^2 = \frac{\sigma^2}{m}$$

$\Rightarrow E \hat{S}_m = \sigma^2 \Rightarrow \hat{S}_m$  je nepr.



### Metoda momentů

$r$ -tý moment  $X$  ...  $m_r := E[X^r]$

$r$ -tý výběr. m.  $X$  ...  $\hat{m}_r := \frac{1}{m} \sum_i X_i^r$       $\parallel$       $\parallel$   
 $E X$       $\bar{X}_m$

$\Rightarrow$  pro odhad  $\theta$  vyřešíme rovnici  $m_r(\theta) = \hat{m}_r$

$\hookrightarrow$  případně soustavu rovnic  $m_r(\theta) = \hat{m}_r$  pro  $r=1, 2, \dots$

Pr: ①  $X_i \sim \text{Ber}(\mu)$   $\rightarrow \theta = \mu$

$m_1 = E X_i = \mu$   
 $\hat{m}_1 = \bar{X}_m$  }  $\hat{\mu} = \bar{X}_m$  ... díky ZVC to je nepr. konz. odhad

②  $X_1, \dots, X_m \sim N(\mu, \sigma^2)$   $\rightarrow$  dva parametry  $\Rightarrow$  2 rovnice

$$m_1 = \mu$$

$$m_2 = E X^2 = \text{var}(X) + (EX)^2 = \sigma^2 + \mu^2$$

$$\Rightarrow \hat{m}_1 = \bar{X}_m = \mu$$

$$\hat{m}_2 = \frac{1}{m} \sum_i X_i^2 = \mu^2 + \sigma^2 = \bar{X}_m^2 + \sigma^2$$

$$\left. \begin{array}{l} \hat{\mu} = \bar{X}_m \\ \hat{\sigma}^2 = \hat{m}_2 - \hat{\mu}^2 \end{array} \right\}$$

• Metoda max. verohodnosti - max. likelihood

→ náhodný výběr  $X_1, \dots, X_n \sim F_\theta$  a realizace  $x_1, \dots, x_n$

↳ předpokládáme  $\sim F_\theta \Rightarrow$  to dáva distribuci

① diskrétní n.v.: Chceme max.  $P[X_1=x_1 \& X_2=x_2 \& \dots \& X_n=x_n]$

↳  $X_1, \dots, X_n$  nezávislé  $\Rightarrow P[X_i : x_i = x_i] = \prod P[X_i = x_i]$

$$\Rightarrow L(\theta, \vec{x}) := \prod_i P[X_i = x_i | \theta]$$

↳ nevíme, kde  $X_i \sim F_\theta$

② spojitá n.v.:  $L(\theta, \vec{x}) := \prod_i f_{X_i | \theta}(x_i)$

$\Rightarrow$  hledám max  $L(\theta, \vec{x})$ ,

→ derivuju podle  $\theta$

respektive  $l(\theta, \vec{x}) := \log L(\theta, \vec{x}) = \sum_i \log(f_{X_i}(x_i))$

Příklady

①  $X_1, \dots, X_n \sim \text{Ber}(p) \Rightarrow \theta = p$

↳  $k := \#1$

$$P(\bar{X} = \bar{x}) = L(p, \bar{x}) = P[X_1=x_1, \dots, X_n=x_n] = p^k (1-p)^{n-k}$$

$$\Rightarrow l(p, \bar{x}) = k \cdot \ln(p) + (n-k) \ln(1-p)$$

$$\Rightarrow \frac{\partial l}{\partial p}(p, \bar{x}) = \frac{k}{p} + \frac{k-n}{1-p} = 0 \Rightarrow \dots \Rightarrow \hat{p} = \frac{k}{n}$$

$\downarrow$   
n max

②  $X_1, \dots, X_n \sim U(0, \theta) \Rightarrow f(x) = \begin{cases} \frac{1}{\theta}, & x \in [0, \theta] \\ 0, & \text{jinak} \end{cases}$

$$L(\theta, \vec{x}) = \prod_i f(x_i) \dots \text{aby to nebyla } 0, \text{ tak } \theta \geq \max_i x_i$$

$$= \prod_i \frac{1}{\theta} = \frac{1}{\theta^n} \dots \text{max} \Rightarrow \theta \text{ co nejmenší} \Rightarrow \hat{\theta} := \max_i x_i$$

③  $X_1, \dots, X_n \sim \text{Geom}(p) \Rightarrow P[X_i = k] = (1-p)^{k-1} \cdot p$

$$L(p, \vec{x}) = \prod_i P[X_i = x_i] = p^n (1-p)^{(\sum x_i) - n}$$

$$\Rightarrow l(p, \vec{x}) = n \log(p) + (\sum x_i - n) \log(1-p)$$

→ předzáložka:  $\log(p) + (\bar{x}_n - 1) \log(1-p)$

$$\rightarrow \text{derivace: } \frac{1}{p} + \frac{1 - \bar{x}_n}{1-p} = 0 \Rightarrow \hat{p} = \frac{1}{\bar{x}_n}$$

## • Intervalové odhady

→ přes bodový odhad odhadneme  $\theta$  jako  $\hat{\theta}$  ... ale typicky  $\hat{\theta} \neq \theta$   
⇒ chceme si být dost jistý, že  $\hat{\theta}$  není moc mimo

Def: Necht'  $D \leq H$  jsou statistiky. Říkáme, že máme  $[D, H]$   
intervalový odhad o spolehlivosti  $(1-\alpha) \equiv P[D \leq \theta \leq H] = 1-\alpha$ .

↳ umožňují chybu  $\alpha \in (0, 1)$

↳ anglicky  $(1-\alpha)$ -confidence interval  $\Rightarrow$   $(1-\alpha)$ -CI

↳ někdy dává smysl uvést i jednostranné odhady ( $D = -\infty$  v  $H = \infty$ )

Značení: Často budeme chtít CI typu  $X \pm \delta := [X - \delta, X + \delta]$ .

Věta: Máme nestranný bodový odhad  $\hat{\theta}$  pro parametru  $\theta$ .


Předpoklad je  $\hat{\theta} \sim N(\mu, \sigma^2)$ , kde

$$\hat{\theta} \pm z_{\alpha/2} \sigma(\hat{\theta}) \text{ je } (1-\alpha)\text{-CI}, \quad z_{\alpha/2} := \Phi^{-1}(1 - \frac{\alpha}{2}).$$

Předpoklad není normálně rozdělené, ale řekneme, že slovo je (CLV)

Důk: Nejprve provedeme standardizaci,  $E\hat{\theta} = \theta$  díky nestranosti

$$Z = \text{stand}(\hat{\theta}) = \frac{\hat{\theta} - E\hat{\theta}}{\sigma(\hat{\theta})} = \frac{\hat{\theta} - \theta}{\sigma(\hat{\theta})} \sim N(0, 1)$$



$$P(-z_{\alpha/2} \leq Z \leq z_{\alpha/2}) = 1-\alpha$$

$$P(-z_{\alpha/2} \leq \frac{\hat{\theta} - \theta}{\sigma(\hat{\theta})} \leq z_{\alpha/2}) = 1-\alpha$$

$$P(\underbrace{\hat{\theta} - z_{\alpha/2} \sigma}_{D} \leq \theta \leq \underbrace{\hat{\theta} + z_{\alpha/2} \sigma}_{H}) = 1-\alpha$$



## Příklady:

①  $X_1, \dots, X_n \sim N(\mu, \sigma^2) \rightarrow \theta = \mu$

↳ máme nestraný odhad  $\hat{\theta} = \bar{X}_n \sim N(?, ?)$

↳  $\mathbb{E}X_n = \mu, \text{Var}(X_n) = \frac{\sigma^2}{n} \Rightarrow \hat{\theta} \sim N(\mu, \frac{\sigma^2}{n})$

$\Rightarrow \bar{X}_n \pm z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}$  je  $(1-\alpha)$ -CI.

②  $X_1, \dots, X_n$  libovolné rozdělení

$\sigma$  známe } hledáme  $\theta := \mathbb{E}X \Rightarrow$  opět odhad  $\bar{X}_n$  pro  $\hat{\theta}$   
n velkých

→ podle CLV je  $\bar{X}_n$  přibližně normálně rozdělený ...  $\frac{\bar{X}_n - \mu}{\sigma(\bar{X}_n)} \approx N(0,1)$

$\Rightarrow \bar{X}_n \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$  je přibližně  $(1-\alpha)$ -CI

↳  $\lim_{n \rightarrow \infty} P(D \leq \theta \leq H) = 1-\alpha \dots \alpha = 30$

↑  
přesněji

→ tedy je pro větší rezervu lepší použít tzv. Student- $t$  rozdělení

Pozn: Najdeme CI tvaru  $x \pm \Delta$ .

↳ jaké  $n$  nám dákový odhad rozdílu pro dané  $\Delta$ ?

$\Delta = z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \Rightarrow n \geq \left(\frac{z_{\alpha/2} \sigma}{\Delta}\right)^2 = \frac{\text{const}}{\Delta^2}$

$\Rightarrow$  pokud chceme  $\Delta$  zmenšit 10x, a zachovat spolehlivost  $\alpha$ ,  
tak potřebujeme 100x víc měření ( $n$ )

③ Dvourázkový test

$X_1, \dots, X_m \sim N(\mu_X, \sigma_X^2)$   
 $Y_1, \dots, Y_n \sim N(\mu_Y, \sigma_Y^2)$  } známe  $\sigma_X, \sigma_Y$ , chceme odhad pro  $\theta := \mu_X - \mu_Y \Rightarrow \hat{\theta} = \bar{X}_m - \bar{Y}_n$

→ máme nestraný odhad pro  $\hat{\theta}$ , protože  $X_i, Y_i$  je norm., takže  $\hat{\theta}$  také normální

→ protože  $X_i, Y_j$  jsou všechny nezávislé, takže

$\text{Var} \hat{\theta} = \text{Var}(\bar{X}_m - \bar{Y}_n) = \text{Var}(\bar{X}_m) + \text{Var}(\bar{Y}_n) = \frac{\sigma_X^2}{m} + \frac{\sigma_Y^2}{n}$

$\Rightarrow \sigma(\hat{\theta}) = \sqrt{\frac{\sigma_X^2}{m} + \frac{\sigma_Y^2}{n}}$

$\Rightarrow \bar{X}_m - \bar{Y}_n \pm z_{\alpha/2} \sigma(\hat{\theta})$  je  $(1-\alpha)$ -CI.



• Intervalové odhady, když neznám rozptyl

① Plug-in estimate

$X_1, \dots, X_n \sim \text{Ber}(p) \Rightarrow \theta = p$ , ale neznám  $\sigma$

$\Rightarrow \sigma(\hat{p}) = ? \dots \text{Var } X_i = p \cdot (1-p) \quad \because X_i \sim \text{Ber}(p)$

$\hookrightarrow \hat{p} = \bar{X}_n \Rightarrow \text{Var } \bar{X}_n = \frac{1}{n} \cdot p(1-p)$

$\Rightarrow \sigma(\hat{p}) = \sqrt{\frac{p(1-p)}{n}} \approx \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$  ... protože neznám  $p$

$\Rightarrow \bar{X}_n \pm z_{\alpha/2} \sqrt{\frac{\bar{X}_n(1-\bar{X}_n)}{n}}$  je  $(1-\alpha)$ -CI

② Studentův test

$X_1, \dots, X_n \sim N(\theta, \sigma^2)$  ...  $\sigma$  neznám

$\hookrightarrow$  nestranný odhad  $\hat{\theta} = \bar{X}_n$ ,  $\sigma(\hat{\theta}) = \frac{\sigma}{\sqrt{n}}$ , ale  $\sigma$  neznám

$\Rightarrow$  odhad  $\hat{\sigma} = \hat{S}_n = \sqrt{\frac{1}{n-1} \sum_i (X_i - \bar{X}_n)^2} \Rightarrow \sigma(\hat{\theta}) = \frac{\hat{S}_n}{\sqrt{n}}$

!  $\hookrightarrow$  důkazem věty děláme normalizaci  $\hat{\theta}$  na stand. normální  $n$ .

$\Rightarrow T_n = \frac{\hat{\theta} - E\hat{\theta}}{\sigma(\hat{\theta})} = \frac{\bar{X}_n - \mu}{\hat{S}_n / \sqrt{n}} \rightarrow$  tohle není konst, ale  $n$ -veličina

$\Rightarrow T_n$  není  $N(0,1)$ , ale něco podobného

Def: Student's t-distribution s  $n-1$  stupni volnosti je přesně toto rozdělení.

$\rightarrow$  distribuční funkci známe  $\Psi_{n-1}(x)$ .

$\hookrightarrow$  python: `scipy.stats.t.cdf(x, n-1)`

$\Rightarrow$  pověřeme odhad  $\rightarrow$  analogie pro  $\bar{X}$

$\hat{\theta} \pm t_{\alpha/2} \cdot \frac{\hat{S}_n}{\sqrt{n}}$ , kde  $t_{\alpha/2} := \Psi_{n-1}^{-1}(1-\alpha/2)$

!  $t_{\alpha/2} > z_{\alpha/2} \Rightarrow$  interval je větší  $\hookrightarrow$  analogie pro  $z_{\alpha/2}$   
 $\hookrightarrow$  neznáme totiž  $\sigma$

Věta: Necht  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ . Neznáme  $\mu$  ani  $\sigma$ , chceme učit  $\mu$ .  
Opět máme  $\alpha \in (0, 1)$ . Necht  $\Psi_{n-1}(\lambda_{\alpha/2}) = 1 - \alpha/2$ . Pak

$$\bar{X}_n \pm \lambda_{\alpha/2} \frac{\hat{S}_n}{\sqrt{n}} \text{ je } (1-\alpha)\text{-CI pro } \mu.$$

## • Testování hypotéz

1) otázka ... nalévají správnou míru piva?  $\rightarrow$

$H_0$  ... nulová hypotéza (konzervativní model) ...  $EX = 500$  ml

$H_1$  ... alternativní hypotéza (významná odchylka) ...  $EX < 470$  ml

2) design experimentu - rozvrhnout před začátkem měření

- vybereme vhodný statistický model ...  $X \sim N(500, \sigma^2)$

- chyba 1. druhu: Zamítneme  $H_0$ , i když ploví ... "Tropas"

$\Rightarrow$  zvolíme hladinu významnosti  $\alpha$  ... typický  $\alpha = 0.05$

$\hookrightarrow$  test konstruujeme tak, aby  $P[\text{ch. 1. d.}] = \alpha$

- chyba 2. druhu: Nezamítneme  $H_0$ , ale ona neploví ... "Promarněná příležitost"

$\Rightarrow$  zvolíme parameter  $\beta \Rightarrow$  pak  $P[\text{ch. 2. d.}] = \beta$

$\hookrightarrow$  hodnota  $1 - \beta$  se nazývá síla testu

- určíme statistický test  $T = h(X_1, \dots, X_n)$  ...  $T = \bar{X}_n$

- určíme kritický obor (rejection region) - množinu  $W$  podle  $\alpha, \beta$

3) naměříme data  $x_1, \dots, x_n \rightarrow$  realizace  $X_1, \dots, X_n$

4) vyhodnocení: pokud  $t = h(x_1, \dots, x_n) \in W \Rightarrow$  zamítneme  $H_0$

$\Rightarrow \alpha = P[T \in W | H_0]$  ... znamená: ve světě, kde ploví  $H_0$

$\Rightarrow \beta = P[T \notin W | H_1]$  ... ve světě, kde ploví  $H_1$

5) výpočet dalších závěrů

$\rightarrow$  pokud  $\alpha = 0.09$  a  $\alpha = 0.05 \Rightarrow$  nezamítnu  
 $\alpha = 0.11 \Rightarrow$  zamítnu

p-value := min.  $\alpha$ , pro kterým bychom  $H_0$  zamítnu  
 $\hookrightarrow$  pro menší  $\alpha$  už ne

## Príklady:

### ① Jednovýberový test

Nalili mi správnou mieru piva?

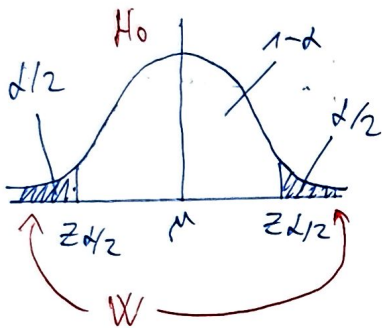
$X_1, \dots, X_m \sim N(\theta, \sigma^2)$ , riešime, že  $\sigma$  vieme reálnejšie

$$H_0: \theta = 500 \text{ ml} \rightarrow \mu := 500 \text{ ml}$$

$$H_1: \theta \neq 500 \text{ ml} \rightarrow \text{pre jednoduchosť}$$

→ chci statistiku niečo jako  $\bar{X}_m$ , ale musím byť udelet  $W$

$$\Rightarrow Z = \frac{\bar{X}_m - E\bar{X}_m}{\sigma(\bar{X}_m)} = \frac{\bar{X}_m - \mu}{\sigma/\sqrt{m}} \rightarrow \text{podle CLV: } Z \sim N(0, 1)$$



→ chci  $P[Z \in W; H_0] = \alpha \Rightarrow P[Z \notin W; H_0] = 1 - \alpha$

$$\Rightarrow W = \{x \in \mathbb{R} \mid |x| > z_{\alpha/2}\} \rightarrow (1 - \alpha)\text{-CI používaj}$$

→ B. závisí na tom, jak blízko je  $\theta$  k 500 ml.

### ② Dvouvýberový test

Nalili mi stejně jako kamarádovi?

$$\left. \begin{array}{l} X_1, \dots, X_m \sim N(\theta_x, \sigma^2) \\ Y_1, \dots, Y_m \sim N(\theta_y, \sigma^2) \end{array} \right\} \begin{array}{l} H_0: \theta_x = \theta_y \\ H_1: \theta_x \neq \theta_y \end{array}$$

, předpokládáme, že víme  $\sigma$

→ zase chci statistiku něco jako  $\bar{X}_m - \bar{Y}_m =: S$

↳ pokud platí  $H_0$ , tak  $E S = 0$

$$\text{↳ Var } S = \text{Var } \bar{X}_m - \text{Var } \bar{Y}_m = \frac{\sigma^2}{m} + \frac{\sigma^2}{m}$$

$$\Rightarrow Z = \frac{S - E S}{\sigma(S)} = \frac{\bar{X}_m - \bar{Y}_m}{\sigma \sqrt{\frac{1}{m} + \frac{1}{m}}} \rightarrow \text{podle CLV: } Z \sim N(0, 1)$$

• Z-test: jako v ①:  $W = \{x \in \mathbb{R} \mid |x| > z_{\alpha/2}\}$

### ③ Co kdybychom $\sigma$ neznali?

↳ v ① a ② jsme vyrobili Z-test. Ted' ①, ale  $\sigma$  neznáme

$$\Rightarrow \text{T-test: } \sigma \approx \hat{S}_m = \frac{1}{m-1} \sum_i (X_i - \bar{X}_m)^2 \Rightarrow \sigma(\bar{X}_m) \approx \frac{\hat{S}_m}{\sqrt{m}}$$

$$\Rightarrow T = \frac{\bar{X}_m - \mu}{\hat{S}_m / \sqrt{m}} \quad \text{a} \quad W = \{x \in \mathbb{R} \mid |x| > t_{\alpha/2}\}, \quad t_{\alpha/2} = \psi_{m-1}^{-1}(1 - \alpha/2)$$

Hypothesis pro kategoričn data - testy dobré shody

→ dostupn numeričn data: kolik volili, # dětí, doba běhu programu

→ házím kostkou ... je spravedlivá? → 6 kategorií

Observed:  $O_1, \dots, O_k$

Expected:  $E_1, \dots, E_k$

1	2	3	4	5	6
92	120	88	98	95	107
100	100	100	100	100	100

→  $H_0$  = kostka je spravedlivá

→ dá se odvodit nějaký rozumný vzoreček pro statistický test

G-test:  $G = 2 \cdot \sum_i O_i \cdot \log \frac{O_i}{E_i}$   $\forall_i E_i = O_i \Rightarrow G = \chi^2 = 0$

$\chi^2$ -test  $\chi^2 = \sum_i \frac{(E_i - O_i)^2}{E_i}$  Taylor. p.

↳ měří vzdálenost od ideálního stavu  $\chi^2 = 6.86$

→ jak zvolit kritický obor pro dané  $\alpha$ ?

⇒ chceme  $P[T > \gamma | H_0] = \alpha$  ... pro  $T = G$  nebo  $T = \chi^2$

↳ jak určit  $\gamma$ ? ... co už je moc velké?

① exaktní test - pro malé  $n = \# \text{samplů}$

pro náš příklad  $\gamma = 11.1 \Rightarrow H_0$

→ projdu všech  $(\# \text{kategorií})^n$  možných výsledků

↳ respektive  $\binom{n+k-1}{n}$  ... musí se to sečíst na  $n$

→ pro  $\forall$  výsledků vyhodnotím  $T$  a určit  $\gamma$ , aby  $T > \gamma$  pouze v 100 $\alpha$  procentech případů

② velké  $n \Rightarrow$  udělám ① s nějakou množinou náhodných vzorků

③ velké  $n$  &  $T = \chi^2 \rightarrow$  aproximace pomocí tzv.  $\chi^2$  rozdělení s  $k-1$  stupni volnosti

$\chi_{k-1}^2$  je rozdělení n.v.  $Q = Z_1^2 + \dots + Z_{k-1}^2$ ,  $Z_i \sim N(0,1)$  přebdlní kategorií dostáváme

↳ dá se ukázat, že  $\chi^2 \approx Q$ . (pokud platí  $H_0$ )

⇒ potom  $\gamma = F_Q^{-1}(1-\alpha) \Rightarrow P[Q > \gamma] = P[\chi^2 > \gamma] = \alpha$ .

## Průběhy testů

- 1-výběrový test  $X_1, \dots, X_m \sim N(\mu, \sigma^2) \rightarrow H_0: \mu = 5$

stats. test - 1samp(x, popmean = 5)

- 2-výběrový test  $X_1, \dots, X_m \sim N(\mu_x, \sigma^2)$   
 $Y_1, \dots, Y_m \sim N(\mu_y, \sigma^2)$  }  $H_0: \mu_x = \mu_y$

stats. test - ind(x, y, equal-var = True)

↳ pokud  $\sigma_x \neq \sigma_y \Rightarrow$  equal-var = False

- párový test  $X_1, \dots, X_m \sim N(\mu_x, \sigma^2)$   
 $Y_1, \dots, Y_m \sim N(\mu_y, \sigma^2)$  }  $H_0: \mu_x = \mu_y$

$\rightarrow X_i, Y_i$  spolu nějak souvisí ... běh algoritmu před / po splnění

$\Rightarrow$  mohl bych udělat 2-výběr.  $t$ -test, ale jde to líp

$\Rightarrow$  udělám  $D_i := X_i - Y_i$  a dělám

1-výběrový  $t$ -test  $D_1, \dots, D_m$  s  $H_0: \overbrace{\mu_x - \mu_y}^{\mu_D} = 0$

stats. test - rel(x, y)

## Lineární regrese

data:  $(x_i, y_i)$  pro  $i=1, \dots, m$

↳ cíl:  $y = ax + b$  ...  $x =$  nezávislá proměnná - predictor  
 $y =$  závislá proměnná - response

↳ chyba regrese měříme pomocí MSE

$$\sum_{i=1}^m (y_i - (ax_i + b))^2 \Rightarrow \text{chceme to minimalizovat}$$

řešení:

$$b = \bar{x}_m / \bar{y}_m$$

$$a = \frac{\sum_i (x_i - \bar{x}_m)(y_i - \bar{y}_m)}{\sum_i (x_i - \bar{x}_m)^2} = \frac{\text{cov}(\bar{x}_m, \bar{y}_m)}{\text{var}(\bar{x}_m)}$$

↑ spíš vytkneme cov a var