

Pravdepodobnosť a štatistika

Na základe prednášok Daniela Hlubinky

Vladislav Vancák



CC-BY-NC-SA 4.0

hlubinska @ Earlin. mff. cam. cz

PRAVDĚPODOBŇNOST:

Pravděpodobnostní prostor:

- d -stěnná kostka \Rightarrow výsledky $1, \dots, d$.

- \forall prvek množiny $\{1, \dots, d\}$ = ELEMENTÁRNÍ JEV

• Ω - MNOŽINA EL. JEVŮ ... měřitelná!

• \mathcal{F} - SYSTÉM PODMNOŽIN Ω : vlastnosti:

I. $\Omega \in \mathcal{F}$ (prvky \mathcal{F} jsou množiny).

II. $A \in \mathcal{F} \Rightarrow \Omega \setminus A \in \mathcal{F}$ (je tam i komplement)

III. Pro libovolné $A_1, A_2, \dots \in \mathcal{F}$ je $\bigcup_i A_i \in \mathcal{F}$ (spčetné & konečné) ... Uzavřenost na spčetná sjednocení.

• \mathcal{F} nazveme σ -algebrou na Ω

• např. $\{\emptyset, \Omega\}$ je σ -algebra.

• pro Ω nejvýše spčetnou je $\mathcal{P}(\Omega)$ σ -algebrou.

\hookrightarrow i pro nepřspčetnou, ale to by dále vedlo k paradoxu.

• prvky \mathcal{F} nazveme náhodné jevy.

• P množinová funkce na \mathcal{F} se nazývá pravděpodobnost / pravděj. míra, pokud:

I. $\forall F \in \mathcal{F} : 0 \leq P(F) \leq 1$ (P vezme \mathcal{F} a přiřadí jí číslo)

II. Pro F_1, F_2, \dots po 2 disjunktí: $P(\bigcup_{i=1}^{n/\infty} F_i) = \sum_{i=1}^{n/\infty} P(F_i)$
... σ -aditivita P

III. $P(\Omega) = 1$.

Def: Trojice (Ω, \mathcal{F}, P) se nazývá PRAVDĚPODOBŇNOSTNÍ PROSTOR.

např. $\boxtimes \dots \Omega = \{1, 2, 3, 4, 5, 6\}$

$\mathcal{F} = \mathcal{P}(\Omega)$

$P(\{i\}) = p_i \quad i = 1, 2, \dots, 6 \quad ; \quad p_i \geq 0 \quad \wedge \quad \sum_{i=1}^6 p_i = 1$

• např. $p_i = 1/6 \quad i = 1..6$ pro pravidelnou.

p_i je "očerávaný podíl výsledku i v mnoha pokusech provedených za stejných podmínek.

Vlastnosti a počítání pravděpodobnosti:

$P(A) = 1 - P(A^c)$... věta o doplňkové pravděpodobnosti

$$P(E_1 \cup E_2) = P(E_1) + P(E_2) - P(E_1 \cap E_2)$$

Dk: Pro $B \subset A$ platí $P(A \setminus B) = P(A) - P(B)$

• $B \cap (A \setminus B) = \emptyset$

• $B \cup (A \setminus B) = A$ → disjunktní

• $E_1 \cup E_2 = E_1 \cup \underbrace{(E_2 \setminus E_1)}_{\subset E_2}$

$$\Rightarrow P(E_1 \cup E_2) = P(E_1 \cup (E_2 \setminus E_1)) = P(E_1) + P(E_2 \setminus (E_1 \cap E_2)) = P(E_1) + P(E_2) - P(E_1 \cap E_2)$$

V: Princip inkluze a exkluze:

Bud' $E_1 \dots E_n$ máhodné jevy. Pak $P(\bigcup_{i=1}^n E_i) =$

$$= \sum_{i=1}^n P(E_i) - \sum_{\substack{i < j \\ 1 \leq i < j \leq n}} P(E_i \cap E_j) + \sum_{\substack{i < j < k \\ 1 \leq i < j < k \leq n}} P(E_i \cap E_j \cap E_k) + \dots + (-1)^{n-1} P(\bigcap_{i=1}^n E_i)$$

Dk: MI:

$n=2$ věta platí

$$P(\bigcup_{i=1}^n E_i) = P(\bigcup_{i=1}^{n-1} E_i \cup E_n) = P(\bigcup_{i=1}^{n-1} E_i) + P(E_n) - P((\bigcup_{i=1}^{n-1} E_i) \cap E_n) =$$

$$= \sum_{i=1}^n P(E_i) - \left(\sum_{1 \leq i < j \leq n-1} P(E_i \cap E_j) \right) + \sum_{1 \leq i < j < k \leq n} P(E_i \cap E_j \cap E_k) - \dots + (-1)^{n-2} P(\bigcap_{i=1}^{n-1} E_i)$$

$$- \sum_{i=1}^{n-1} P(E_i \cap E_n) + \sum_{\substack{i=1, j \leq n-1, j > i}} P(E_i \cap E_j \cap E_n) + (-1)^{n-1} P(\bigcap_{i=1}^n E_i) =$$

$$= \sum_{\substack{j > i \\ 1 \leq i < j \leq n}} P(E_i \cap E_j)$$

to, co sme dceli.

Pr. 20-ti sterna' hostra. Cislo delit. 3? $P = 6/20$

... padlo c. delit. 4, jara' je padej, ze padlo c. delit.

3 : 4, 8, 12, 16, 20

↳ 1/5

→ Delit. 3 ma' mensi' padej, porad padlo delit.

co drěma? 2, 4, 6, 8, 10, 12, 14, 16, 18, 20 $\rightarrow 3/10 \rightarrow$ nezávislé

Def: (nezávislost jevů):

i. Náhodné jevy E_1, E_2 jsou nezávislé, pokud $P(E_1 \cap E_2) = P(E_1)P(E_2)$

- $\frac{P(D_2) \cdot P(D_3)}{\text{nezávislé}} = P(D_2 \cap D_3)$, ale $\frac{P(D_4) \cdot P(D_3)}{\text{závislé}} \neq P(D_4 \cap D_3)$.

ii. Náhodné jevy $E_i, i \in I$ jsou vzájemně nezávislé, pokud pro každou podmnožinu $I' \subset I$ platí $P(\bigcap_{i \in I'} E_i) = \prod_{i \in I'} P(E_i)$.

Jevy $E_i, i \in A$ jsou po dvou nezávislé, pokud $\forall i, j \in A$ platí $P(E_i \cap E_j) = P(E_i)P(E_j)$.

Pozn. Vzájemně nezávislé jevy jsou také po 2 nezávislé, ale NE NUTNĚ NAOPAK. např.:

$\Omega = \{1, 2, 3, 4\}$ a $p_i = 1/4 \forall i$.

$E_1 = \{1, 2\}$ $E_1 \cap E_2 = \{1\}$ $P(E_1) = P(E_2) = P(E_3) = 1/2$.

$E_2 = \{1, 3\}$ $E_1 \cap E_3 = \{1\}$ $P(E_1 \cap E_2) = 1/4 = P(E_1)P(E_2)$

$E_3 = \{1, 4\}$ $E_2 \cap E_3 = \{1\}$ $P(E_1 \cap E_3) = 1/4$

JSOU PO 2 NEZ. $P(E_2 \cap E_3) = 1/4$

ALE: $E_1 \cap E_2 \cap E_3 = \{1\}$

$P(E_1 \cap E_2 \cap E_3) = 1/4 \neq P(E_1)P(E_2)P(E_3) \Rightarrow$ Nejsou vz. nezávislé!

PROČ?:

mastaly E_1 i $E_2 \Rightarrow$ padla 1 \Rightarrow mastal i E_3 .

mastal E_1 ale ne $E_2 \Rightarrow$ padla 2 \Rightarrow nemastal ani E_3 .


ne E_1 , ani $E_2 \Rightarrow$ padla 4 \Rightarrow mastal E_3 .

\Rightarrow To, jestli mastal E_1 a E_2 určuje $E_3 \Rightarrow$ nejsou nezávislé!


Def: (podmíněná pravděpodobnost):

Bud' E a F náhodné jevy, $P(F) > 0$. Podmíněná pravd. E za podmínky F je dána $P(E|F) = \frac{P(E \cap F)}{P(F)}$.

Plati: $P(F|F) = 1$.



$P(\cdot|F)$ je pravděpodobnost splňující axiomy I-III. pro P .



V: Jsou-li E a F nezávislé jevy, $P(F) > 0$, pak $P(E|F) = P(E)$.

Dk: z definice: $P(E|F) = \frac{P(E \cap F)}{P(F)} = \frac{P(E)P(F)}{P(F)} = P(E)$

Pozn. \forall jev s nulovou $P(E)$ a každým jev A $P(E) = 0$ je nezávislý s libovolným jevem.

Věty užitečné pro výpočet pravděp.:

Tvrzení: E_1, \dots, E_m náhodné jevy takové, že $P(E_1 \cap E_2 \cap \dots \cap E_m) > 0$.

pak $P(E_1 \cap \dots \cap E_m) = P(E_m | E_1 \cap \dots \cap E_{m-1}) \cdot P(E_{m-1} | E_1 \cap \dots \cap E_{m-2}) \cdot \dots \cdot P(E_2 | E_1) \cdot P(E_1)$

Dk: z definice: $P(E_m \cap (E_{m-1} \cap \dots \cap E_1)) = P(E_m | E_1 \cap \dots \cap E_{m-1}) \cdot P(E_1 \cap \dots \cap E_{m-1})$ a post. opak. dostaneme výsledek.

Tvrzení: (věta o úplné pravděp.) E_1, \dots, E_m náhodné jevy:

- i.) $E_i \cap E_j = \emptyset \quad \forall i \neq j$
 - ii.) $P(E_i) > 0 \quad \forall i$
 - iii.) $\bigcup_{i=1}^m E_i = \Omega$
- } Disjunktmi rozklad.

a B náhodný jev. pak $P(B) = \sum_{i=1}^m P(B|E_i) P(E_i)$

Dk: $P(B) = P(B \cap \Omega) = P(B \cap (\bigcup_{i=1}^m E_i)) = P(\bigcup_{i=1}^m (B \cap E_i)) = \sum_{i=1}^m P(B \cap E_i) = \sum_{i=1}^m P(B|E_i) \cdot P(E_i)$ \hookrightarrow po 2 disjunktui

... POZN: věta plati i pro spočetný disj. rozklad.

Věta (Bayesova):

Za podmínek i-iii) + $P(B) > 0$ platí $P(E_i | B) = \frac{P(B|E_i)P(E_i)}{\sum_{j=1}^m P(B|E_j)P(E_j)}$

$P(E_i)$... apriorní rozdělení (pravděp)

B ... informace

$P(E_i | B)$ aposteriorní pravděp.

Důkaz:

$$P(E_i | B) = \frac{P(E_i \cap B)}{P(B)}$$

... v čitateli: $P(E_i \cap B) = P(B|E_i)P(E_i)$
 ... v menovateli: $P(B) = \sum_{j=1}^m P(B|E_j)P(E_j)$

Pr:

2 polynomy $R(x) = (x-a_1)(x-a_2)\dots(x-a_n)$, $a_i \in \mathbb{Z} \setminus \mathbb{Z}$
 $Q(x) = x^m + \dots$ má celoč. kořeny

Odhalte $Q \neq R$

\rightarrow dosadíme třeba 1 do $R(x) - Q(x)$. Pať jsou-li R a Q různé, jen s malou pravděp. dostaneme 0. $R - Q$ má nejvýše m různých kořenů. Vezmeme 100 m různých ~~kořenů~~ celých čísel a z nich 1 náhodně vybereme.

Pravděpodobnost toho, že vybrané číslo je kořen $R - Q$ (jsou-li $R \neq Q$) je nejvýše $\frac{m}{100m} = 1/100$.

\Rightarrow Vybereme-li náhodně k čísel z oněch $100m$, pať jsou-li $R \neq Q$, pať $P(R(x_i) = Q(x_i), \forall i = 1 \dots k) \leq (1/100)^k$
 ? Co kdybychom vybírali bez vracení, t.j. pokud $R(x_i) = Q(x_i)$, tať x_i již nezadáme (nevybíráme ho dál).

$$P(R(x_i) = Q(x_i), i = 1, 2, \dots, k) = P(R(x_k) = Q(x_k) | R(x_i) = Q(x_i), i = 1 \dots k-1) * P(R(x_{k-1}) = Q(x_{k-1}) | R(x_i) = Q(x_i), i = 1 \dots k-2) * \dots * P(R(x_2) = Q(x_2) | R(x_1) = Q(x_1)) * P(R(x_1) = Q(x_1))$$

$m-1$ kořenů

$$\leq \frac{m-1}{100m-1} < \frac{1}{100} \leq \frac{1}{100}$$

$$\leq \prod_{i=1}^{k-1} \frac{m-i}{100m-i} \cdot \frac{1}{100} < \left(\frac{1}{100}\right)^k$$

Náhodná veličina:

hod dřeva Rostráči

$$\Omega = \{1, 2, \dots, 6\}^2$$

$$\omega = (i, j) \quad \begin{array}{l} i \in \{1, \dots, 6\} \\ j \in \{1, \dots, 6\} \end{array}$$

Součet bodů na Rostráči.

$$\omega = (\omega_1, \omega_2) \rightsquigarrow \omega_1 + \omega_2$$

$$X: \Omega \rightarrow \mathbb{R} \quad \text{zde } X(\omega) = \omega_1 + \omega_2$$

X je náhodná veličina,

$$P(X=x) ?$$

$$P(X=4) ? \Rightarrow P(X=4) = P(\{1,3\}, \{2,2\}, \{3,1\}) = \frac{3}{36} = \frac{1}{12}$$

$$P(X=2) = \frac{1}{36} = P(X=12)$$

$$P(X=3) = \frac{2}{36} = P(X=11)$$

$$P(X=4) = \frac{3}{36} = P(X=10)$$

$$P(X=5) = \frac{4}{36} = P(X=9)$$

$$P(X=6) = \frac{5}{36} = P(X=8)$$

$$P(X=7) = \frac{6}{36}$$

$$\Omega' = \{2, \dots, 12\}$$

$$X': \Omega' \rightarrow \mathbb{R}$$

$$X'(\omega) = \omega$$

$$P'(\omega) = \frac{2}{36}$$

Definice: Zobrazení $X: \Omega \rightarrow \mathbb{R}$ takové, že $\forall a \in \mathbb{R}: X^{-1}(-\infty, a] = \{\omega: X(\omega) \leq a\} \in \mathcal{F}$ nazveme náhodná veličina. (M)

Poznámka: Pokud je X diskrétní, tedy nabývá nejvýše spočetně mnoha hodnot, můžeme vždy volit Ω spočetnou a $\mathcal{F} = \mathcal{P}(\Omega)$ (v podmnožině) a X pak vždy splňuje (M).

Definice: (Rozdělení náhodné veličiny): Bude $X: \Omega \rightarrow \mathbb{R}$ náhodná veličina a (Ω, \mathcal{F}, P) pravděp. prostor. Rozdělením náh. velič. X rozumíme pravděp. míru P_X na \mathbb{R} takovou, že $P_X((a, b]) = P(\{\omega: X(\omega) \in (a, b]\}) = P(\{\omega: X(\omega) \leq b\}) - P(\{\omega: X(\omega) \leq a\}) \forall a < b$.

Poznámka: Takto zavedená pravděp. P_X může být rozšířena na borelovskou σ -algebru, t.j. nejmenší σ -algebru obsahující všechny otevřené podmnožiny \mathbb{R} , speciálně \forall intervaly a jednobodové množiny a jejich konečná (i spočetná) sjednocení.

Tvrzení: Pro diskrétní náhodnou veličinu X (t.j. má hodnoty v nějaké nejvýše spočetné podmnožině $S \subset \mathbb{R}$) je rozdělení jednoznačně dáno hodnotami $\{p_s, s \in S\}$ $p_s = P(X=s) = P(\{\omega: X(\omega)=s\})$.

$P_X((a, b]) = \sum_{s \in S \cap (a, b]} f_s$ splňuje vlastnosti pravděp.

hodnoty $\{f_s, s \in S\}$


je hustota rozdělení X vůči číselní míře, na S .

Musi platit $L(A) = |A|$ - počet bodů A
 $f_s \geq 0 \quad \forall s$ - vhodné pro konečné / spočetné množiny.
 $\sum_{s \in S} f_s = 1$

\rightarrow klasická pravděp.:

$P(A) = \frac{|A|}{|\Omega|}$, zde $|\Omega| < \infty$

... ale co s $|\Omega| = \infty$, ale Ω spočetná?



$$P(A) = \sum_{s \in A} f_s \quad L(A) = \sum_{s \in A} 1$$

např. $\Omega = \mathbb{N}$; $f_s = 2^{-s}$

Definice (Distribuční funkce):

$F: \mathbb{R} \rightarrow [0, 1]$ je def. jako $F(x) = P(X \leq x)$, což pro

diskrétní náhodnou veličinou je $F(x) = \sum_{s \in X} f_s$

je distribuční funkce F , takže i hustota $\{f_s, s \in S\}$ plně char. rozdělení náh. veličiny X , tedy pravděp. P_X .

$\Rightarrow P_X$ je jednoznačně dána F .

RŮZNÉ NÁHODNÉ VELIČ. MOHOU MÍT STEJNÉ ROZDĚLENÍ.

Náhodná veličina a její rozdělení:

(Ω, \mathcal{F}, P) , $X: \Omega \rightarrow \mathbb{R}$

Chceme, aby $\{\omega: X(\omega) \leq a\} \in \mathcal{F}$

$X^{-1}((-\infty, a]) \in \mathcal{F}$, t.j. $[X \leq a]$ je náhodný jev a známe $P[X \leq a]$.

Rozdělení n.v. je míra na \mathbb{R} .

Pravděpodobnost $(P_X)((-\infty, a]) = P(X \leq a)$



Rozdělení náhodné veličiny

Rozdělení je vždy pravej. na reálných číslech,

Ω je mat. nástroj pro modelování & důkaz.

míra: Množinová funkce (t.j. vezme množinu a přiřadí jí hodnotu v \mathbb{R} nezápornou).

Příklad: Lebesgueova míra λ na \mathbb{R}

$$\lambda(a, b) = b - a \text{ pro } b > a \text{ (interval)}$$

$$\lambda[a, b] = b - a$$

$$\lambda(\{a\}) = 0$$

Číselná míra (aritmetická) $\lambda(A) = |A|$ hodí se pro nejvíce

specifické množiny, $\lambda_{\mathbb{N}}$ je číselná míra na přiroz. číslech

$$B \subset \mathbb{R} \quad \lambda_{\mathbb{N}}(B) = \sum_{n=1}^{\infty} \mathbb{1}(n \in B) = |B \cap \mathbb{N}|$$

$\mathbb{1}$ - indikátor

$$\mathbb{1}(n \in B) \Leftrightarrow \mathbb{1}_B(n) = \begin{cases} 1 & n \in B \\ 0 & n \notin B \end{cases}$$

Uplný popis náhodnosti je dán hodnotami

$(P_X(B), B \in \mathcal{B})$ - algebry obsahující všechny otevřené intervaly

borelovská

Toto je velice složité & nepřehledné!

Náště stačí distribuční funkce

$$F_X(a) = P[X \leq a] = P_X((-\infty, a]) \quad F_X: \mathbb{R} \rightarrow [0, 1]$$

Znáte-li F_X , pak lze jednoznačně určit P_X .

Tvrzení (vlastnosti F_X): Mějme (Ω, \mathcal{F}, P) a náh. veličinu X

a její distribuční funkci F_X . Pak

i) F_X je nelesající a zprava spojité.

ii) $\lim_{a \rightarrow -\infty} F_X(a) = 0, \lim_{a \rightarrow \infty} F_X(a) = 1$

De $a < b$ $F_X(a) = P(X \leq a) = P[\omega : X(\omega) \leq a] = P[\omega : X(\omega) \leq a \text{ a } \{\omega : X(\omega) \leq b\}] \leq P[\omega : X(\omega) \leq b] = F_X(b)$

Pozn. $\{\omega : X(\omega) \leq a\} = \bigcap_{n=1}^{\infty} \{\omega : X(\omega) \leq a_n\}$
 $a_n \rightarrow a+$

$F_X(a_n) = P[\omega : X(\omega) \leq a_n] = P[\omega : X(\omega) \leq a] = P[\bigcap_{m=1}^{\infty} \{\omega : X(\omega) \leq a_m\}]$

$P(\{\omega : X(\omega) \leq a\}) = P[\bigcap_{n=1}^{\infty} \{\omega : X(\omega) \leq a_n\}] = \lim_{N \rightarrow \infty} P[\bigcap_{n=1}^N \{\omega : X(\omega) \leq a_n\}] =$
 $\stackrel{''}{=} F_X(a)$

$= \lim_{N \rightarrow \infty} P[\{\omega : X(\omega) \leq a_N\}] = \lim_{N \rightarrow \infty} F_X(a_N)$

Spojitosť zleva neplatí, pretože

$\{\omega : X(\omega) < a\} \neq \bigcup_{n=1}^{\infty} \{\omega : X(\omega) \leq a_n\} = \{\omega : X(\omega) < a\}$

Takže $\left| F_X(a) - \lim_{a_n \rightarrow a^-} F_X(a_n) \right| = P[X=a]$
 \rightarrow veličnosť rodu F_X v a

Důkaz ii) $F_X(a) = P[X \leq a]$

$\lim_{a \rightarrow -\infty} F_X(a) = P[\bigcap_{n=1}^{\infty} \{\omega : X(\omega) \leq -n\}] = 0$
 $= \emptyset$

$\lim_{a \rightarrow \infty} F_X(a) = P[\bigcap_{n=1}^{\infty} \{\omega : X(\omega) \leq n\}] = 1$
 $= \Omega$

Věta: Bnd⁻ F funkce splňující i a ii) z 1. Pak existuje (Ω, \mathcal{F}, P) pravděp. prostor a náh. veličina X , taž, že F je její distribuční funkce.

Důkaz:

Volme $\Omega = \mathbb{R}$, \mathcal{F} σ -algebra nad \forall otv. množ. a $P(-\infty, a] = F(a)$. Náhodná veličina $X(\omega) = \omega$ má distrib. funkci $P[\{\omega, X(\omega) \leq a\}] = P[\{\omega : \omega \leq a\}] = P(-\infty, a] = F(a)$.

Def.: Diskrétní náhodná veličina X je tažová, po $\Omega \subseteq \mathbb{R}$ nejvíce spočetná množina $S \subset \mathbb{R}$ splňující $P[X \in S] = 1$ $\{ \omega : X(\omega) \in S \} = \Omega$ X je celočíselná náh. veličina (CNV), pokud X je diskrétní a $S = \mathbb{Z}$

Tvrzení: Bud' X CNV. Pak její rozdělení je plně popsáno HUSTOTOU $\{ p_z, z \in \mathbb{Z} \}$, kde $p_z = P[X=z]$

Platí: X je CNV $\Rightarrow p_z \geq 0 \quad \forall z \in \mathbb{Z} \quad \sum_{z \in \mathbb{Z}} p_z = 1$

$$\sum_{\omega} [X \in S] = \sum_{x \in S} [X=x]$$

$$\downarrow \qquad \qquad \downarrow$$

$$P[\cdot] = 1 \qquad \sum P[\cdot] = 1$$

Příklad: Bernoulliho náhodná veličina máme páras a ten dopadne úspěšně neúspěšně

$(\Omega, \mathcal{F}, P) \quad X(\omega) = \begin{cases} 1 & (\text{úspěch}) \\ 0 & (\text{neúspěch}) \end{cases}$



$p_0 \in (0,1) \quad p_1 = 1 - p_0 \quad p_2 = 0 \quad p_0 \neq 0,1$

Rozdělení $p_1 = p$
 $p_0 = 1 - p \quad p \in (0,1)$

p je parameter tohoto rozdělení se nazývá alternativní a parametrem p .

Distribuční funkce: $F(a) = P[X \leq a]$

$a < 0 \quad P[X \leq a] = 0$
 $0 \leq a < 1 \quad P[X \leq a] = P[X=0] = 1-p$
 $1 \leq a \quad P[X \leq a] = 1$



Na jednom (Ω, \mathcal{F}, P) může být mnoho náh. veličin

$$X: \Omega \rightarrow \mathbb{R}$$

X, Y : CNV

$$Y: \Omega \rightarrow \mathbb{R}$$

? souvztašené rozdělení X a Y , resp.

$$P[X=m, Y=l] \quad \forall m, l \in \mathbb{Z}$$

||

$$P\{\omega: X(\omega)=m\} \cap \{\omega: Y(\omega)=l\}$$

Def: CNV X a Y jsou nezávislé, pokud $\forall m, l \in \mathbb{Z}$ platí,

$$P[X=m, Y=l] = P[X=m]P[Y=l]$$

CNV X_1, \dots, X_n jsou vzájemně nezávislé, pokud $\forall I \subset \{1, \dots, n\}$ a

$$\text{pro } \forall m_i \in \mathbb{Z}, i \in I \text{ platí } P[\bigcap_{i \in I} \{X_i = m_i\}] = \prod_{i \in I} P[X_i = m_i]$$

Charakteristiky náhodné veličiny (MOMENTY náh. velic.):

STŘEDNÍ HODNOTA CNV:

Def CNV X má konečnou střední hodnotu, pokud

$$\sum_{m \in \mathbb{Z}} |m| P[X=m] = \sum_{m \in \mathbb{Z}} |m| p_m < \infty$$

$$\text{a v tom případě } EX = \sum_{m \in \mathbb{Z}} m \cdot p_m$$

Střední hodnota (Expectation)

Věta Pro CNV X a Y s konečnou EX, EY platí $E(X+Y) = EX + EY$

Důkaz

$$E(X+Y) = \sum_{m \in \mathbb{Z}} m \cdot p_{X+Y} P(X+Y=m) = \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} (k+l) P(X=k, Y=l)$$

$$= \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} k P(X=k, Y=l) + \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} l P(X=k, Y=l) =$$

$$= \sum_{k \in \mathbb{Z}} k \sum_{l \in \mathbb{Z}} P(X=k, Y=l) + \sum_{l \in \mathbb{Z}} l \sum_{k \in \mathbb{Z}} P(X=k, Y=l) = \sum_{k \in \mathbb{Z}} k P[X=k] + \sum_{l \in \mathbb{Z}} l P[Y=l] =$$

Podle věty o úplné

pravděp. = $P[X=k]$

$$= EX + EY$$

indukcií X_1, \dots, X_n CNV, $EX_i < \infty \forall i$

$$E(\sum X_i) = \sum EX_i$$

Věta: Bud' X CNV a $c \in \mathbb{R}$ $EX < \infty$ Pak $E(cX) = c \cdot EX$

Důk. $E(cX) = \sum_{k \in \mathbb{Z}} c \cdot k \cdot P[X=k] = c \cdot EX$

CNV = celočíslná náhodná veličina.

$$P[X \in \mathbb{Z}] = 1$$

Střední hodnota $EX = \sum_{i \in \mathbb{Z}} i P(X=i)$

Pokud $P[X \in A] = 1$

$$P[X \in \{0, 1, \dots, m\}] = 1$$

Pokud $E|X_i| < \infty$ pro $i=1, \dots, m$, pak $E \sum_{i=1}^m U X_i = \sum_{i=1}^m U EX_i$

\rightarrow jde o váhy $\Rightarrow EX$ je vážený průměr hodnot CNV X_i , vážený pravděpodobnosti.

Střední hodnota má tyto významy:

1. Pro rozdělení náh. velič. X jde o charakt. "polohy"

$$E(X+a) = EX + a$$

X a Y mohou mít stejnou st. hodnotu, ale naprosto různá rozdělení.

\rightarrow Hod kostek $\rightarrow P[X=i] = 1/6$ $EX = 7/2$

Další charakteristiky náh. veličin.

Def: Momentem náhodné veličiny rozumíme hodnotu $EX^k = \sum_{i \in \mathbb{Z}} i^k P[X=i]$

má-li tento součet smysl pro dané $k \in \mathbb{N}$

EX je první moment náh. veličiny X .

Def: Centrálním momentem náhodné veličiny rozumíme hodnotu

$$E(X - EX)^k = \sum_{i \in \mathbb{Z}} (i - EX)^k P[X=i]$$
 má-li pravá strana smysl.


Def: Pokud $EX^2 < \infty$, pak $E(X - EX)^2$ nazveme rozptylem náhodné velič. X .

Je-li $EX^2 = \infty$, pak buď EX neexistuje, \rightarrow ani rozptyl \neq ,

$$P[X=i] = \frac{2}{i^{1+\epsilon}} \quad i=1, 2, \dots \quad \sum_{i=1}^{\infty} \frac{1}{i^{1+\epsilon}} < \infty$$

$$P[X=-i] = \frac{2}{i^{1+\epsilon}} \quad i=1, 2, \dots \quad EX = \sum_{i=1}^{\infty} \frac{2 \cdot i}{i^{1+\epsilon}} - \sum_{i=1}^{\infty} \frac{2 \cdot i}{i^{1+\epsilon}} = \infty - \infty$$

NEBO $E|X| < \infty \Rightarrow$ m.v. X má meromerný rozptyl.



Rozptyl charakterizuje variabilitu náhodnej veličiny okolo jej strednej hodnoty
 \leadsto STREDNÍ ČTVERCOVÁ ODCHYLKA

$$(E) \quad ()^2 \quad (X-EX)$$


Pr: $P[X=i] = 1/6 \quad i=1 \dots 6 \quad EX = 7/2 \quad (1)$

$P[Y=j] = 1/2 \quad j=1, 6 \quad EY = 7/2 \quad (2)$

(1) ROZPTYL = $\text{var } X = E(X-EX)^2 = \sum_{i=1}^6 (i-7/2)^2 \cdot 1/6 = 1/3 \sum_{i=1}^6 (i-7/2)^2 =$
 $= (1/3) \left((5/2)^2 + (3/2)^2 + (1/2)^2 \right) = 35/12$

(2) $E(Y-EX)^2 = \left(\frac{5}{2} \right)^2 = 25/4 = 145/12$

$EX = EY = EZ$




$\text{var } Z < \text{var } X < \text{var } Y$

Jensenova nerovnosť.

Obecně neplatí $E f(X) = f(EX)$

Věta: Bude X náh. veličina a f konvexní funkce takové, že

$E|X| < \infty$ a $E|f(X)| < \infty$. Pak $E f(X) \geq f(EX)$.



$P[X=-1] = 1/2 \quad EX = 0$

$P[X=1] = 1/2$

$(EX)^2 = 0$

$\Rightarrow (EX)^2 \leq EX^2$

$EX^2 = 1$

Lemma: Je-li f dvakrát diferencovatelná, pak $f''(x) \geq 0$

$\forall x \Leftrightarrow f$ je konvexní

Dě věty

z Taylorova rozvoje f kolem $EX = c$ takové, že

$f(x) = f(EX) + (x-EX) f'(EX) + \frac{(x-EX)^2}{2} f''(c) \geq f(EX) + (x-EX) f'(EX)$

$\cdot f'(EX) \leadsto$ dosadit náh. veličinu + přiměřovat.

$$E f(X) \geq \underbrace{E f(EX)}_{\text{konstanta}} + \underbrace{E(X-EX)}_{\text{konstanta}} f'(EX)$$

$$E(X-EX) = EX - EX = 0$$

$$\Rightarrow E f(X) \geq E f(EX)$$

... důkaz po f obecnou myšleň z faktu
 $f = \sup \{a : a \leq f, a \text{ je afinní}\}$

$$\text{var } X = E(X-EX)^2 = E(X^2 - 2XEX + (EX)^2) = EX^2 - 2E(XEX) + E(EX)^2 = EX^2 - 2(EX)(EX) + (EX)^2 = EX^2 - (EX)^2 > 0$$

Základní vlastnosti rozptylu

$$\text{var}(X+a) = E(X+a - E(X+a))^2 = E(X+a - EX - a)^2 = E(X-EX)^2 = \text{var } X$$

$$\text{var}(c) = E(c - E c)^2 = 0$$

$$\text{var}(cX) = E(cX - E cX)^2 = E c^2 (X-EX)^2 = c^2 \cdot \text{var } X$$

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

$$\Rightarrow \text{var}(X+Y) = \text{var } X + \text{var } Y + 2E(X-EX)(Y-EY)$$

Def: Bud (Ω, \mathcal{F}, P) pravděj. prostor. zobrazení $X: \Omega \rightarrow \mathbb{R}^k$ ($k \geq 2$) splňující $\{\omega: \bigcap_{i=1}^k \{\omega: X_i(\omega) \leq a_i\}\} \in \mathcal{F} \forall (a_1, \dots, a_k) \in \mathbb{R}^k$ (Pozn. $\underline{X}_k(\omega) = (X_1(\omega), \dots, X_k(\omega))$ nazveme k -rozměrný náhodný vektor.

Pozor: \forall složka náh. vektoru \underline{X} je náhodnou veličinou

Def: (ROZDĚLENÍ NÁH. VEKTORU)

Pravdějodobnost $P_{\underline{X}}$ def. na \mathbb{R}^k předpisem $P_{\underline{X}}[\bigcap_{i=1}^k (-\infty, a_i]] =$

$$= P[\bigcap_{i=1}^k (X_i \leq a_i)] = P\{\omega: \bigcap_{i=1}^k \{\omega: X_i \leq a_i\}\}$$

se nazývá SDRUŽENÉ ROZDĚLENÍ NÁH. VEKTORU \underline{X} .

hod dréjma rostlami

$X_1 =$ součet oř

$X_2 =$ abs. hodnota rozdílu

$$X_1 = 2 \quad X_2 = 0 \quad \rightsquigarrow 1/36$$

$$X_1 = 3 \quad X_2 = 1 \quad \rightsquigarrow 2/36$$

$$X_1 = 4 \quad X_2 = 2/0 \quad \rightsquigarrow 4/36$$

Def:

Pro podvektor $Y = (X_{i_1}, \dots, X_{i_d})$, $d \leq k$ máh. vektoru X definujeme marginální rozdělení X jako

$$P_Y \left(\prod_{j=1}^d (-\infty, a_{ij}] \right) = P \left\{ \omega : \prod_{j=1}^d \{ \omega : X_{i_j} \leq a_{ij} \} \right\} =$$

$$= P \left\{ \omega : \prod_{i=1}^d \{ \omega : X_i \leq a_i \} \right\}, \text{ kde } a_i = \infty \text{ pro } i \neq i_1, \dots, i_d$$

Pozn. $\{ \omega : X_i \leq \infty \} = \Omega$ (\Rightarrow nic nenbyde)

Speciálně $P_X(-\infty, a_i] = P \{ \omega : X_i \leq a_i \}$

SDRUŽENÉ ROZDĚLENÍ jednoznačně určuje marginální.

MARGINÁLNÍ rozdělení se do sdrúženého dají složit nezávisle

způsoby.

Náhodný vektor:

$$X = (X_1, \dots, X_k) : \Omega \rightarrow \mathbb{R}^k$$

$$P(X_1 \leq a_1, \dots, X_k \leq a_k) = P \left\{ \omega : \prod_{i=1}^k \{ X_i(\omega) \leq a_i \} \right\}$$

$$P_X \left(\prod_{i=1}^k (-\infty, a_i] \right) \dots \text{SDRUŽENÉ ROZDĚLENÍ}$$

Marginální rozdělení je rozdělení podvektoru máh. vektoru X ,

např. rozdělení (X_1, \dots, X_{k-1}) , a to dostaneme z X polbou $a_k = \infty$

Nejdůležit. (neponužir.) jsou rozdělení jednotlivých složek

$$X_1, X_2, \dots, X_k.$$

Pr. 1.) (X, Y) ... máme 2 ma kostkami:

X je ~~výsledek~~ výsledek na 1. kostce

Y součet na obou kostkách.

X	1	2	3	4	5	6	7	8	9	10	11	12					
	1	$1/6$	$(6, 12) = 1/36$		
	2	$1/6$	$\cdot = 1/36$		
	3	$1/6$			
	4	$1/6$			
	5	$1/6$			
	6	$1/6$			
		2	3	4	5	6	7	8	9	10	11	12					

\rightarrow chceme marg. rozdel. $X \Rightarrow Y$ uvolnim a scitam: ($\forall 1/6$)

$$P(X=j) = \sum_{i=1}^{12} P(X=j, Y=i) = 6 \times 1/36 = 1/6 \text{ (pre } \forall j)$$

\rightarrow chceme marg. rozdel. $Y \Rightarrow X$ uvolnim \rightarrow

$$P(Y=j) = \sum_{i=1}^6 P(Y=j, X=i) \quad \# \quad \rightarrow \text{podľa } \uparrow$$

Marginalni $\rightarrow P(X=5) = 1/6, P(Y=6) = 5/36$

Združenie $\rightarrow P(X=5, Y=6) = 1/36$

2.) 3 kostky, X vysl. na 1., Y součet na 2. a 3.

		2	3	4	5	6	7	8	9	10	11	12	
1	$(1,1,1)$	$(1,1,2)$	$(1,2,1)$	3.									
2	$(2,1,1)$..	3.										$\cdot = 1/216$
3	.	..	3.	4.	5.	6.	5.	4.	3.	2.	1.		
4	.	..	3.										
5	.	..	3.										
6	.	..	3.										

$\sum_m P(X=m, Y=m) = P(X=m) P(Y=m) \rightarrow$ Nezávislé. + stále $P(X=i) = 3^6/216 = 1/6 \checkmark$

$Y=3 \rightarrow (1,1,2)$ alebo $(1,2,1)$

$1/36 \quad 2/36 \quad 3/36 \quad 4/36 \dots$

ale $P(Y=i)$ je iná \rightarrow
 $3/36 \quad 2/36 \quad 1/36$

Značenie: CNV = celočísľavý náhodný vektor = náhodný vektor, jehož složky jsou celočísľavné náh veličiny.

Def: CNVeličiny X a Y jsou nezávislé, pokud $\forall m, m \in \mathbb{Z}$ platí

$$P(X=m, Y=m) = P(X=m) P(Y=m)$$

neboli sdružené rozdělení je součinem marginálních.

Náhodné veličiny X, Y jsou nezávislé, pokud sdružené rozdit. (X, Y) je součinem marg. rozdělení X a Y .

~> Všeobecně?

Def (Nezávislost CNV obecně):

CNVeličiny X_1, \dots, X_k se nazývají (vzájemně) nezávislé, pokud $\forall m_i \in \mathbb{Z}; i=1..k$ platí

$$P(X_1=m_1, \dots, X_k=m_k) = \prod_{i=1}^k P(X_i=m_i)$$

~> Tedy lze zdefinovat podmíněné rozdělení:

Def: Bud' (X, Y) CNV. Rozdělení (k-erné)

$$P[X=l | Y=l] = \frac{P[X=l, Y=l]}{P[Y=l]} ; P[Y=l] > 0, l \in \mathbb{Z}$$

nazveme podmíněné rozdělení X za podmínky $Y=l$

~> spát k # k rozbám. (vyřezané 2. a 5. stlpec)

Pr: $Y \quad 2 \quad 5$

$$1 \quad \cdot \quad \cdot \quad P[X=1 | Y=2] = \frac{P[X=1, Y=2]}{P[Y=2]} = \frac{1/36}{1/36} = 1$$

$$2 \quad \cdot \quad \cdot$$

$$3 \quad \cdot \quad \cdot \quad P[X=3 | Y=5] = \frac{P[X=3, Y=5]}{P[Y=5]} = 1/4$$

$$4 \quad \cdot \quad \cdot$$

$$5 \quad \cdot \quad \cdot$$

$$6 \quad P[X=1 | Y=5] = 1/4$$

$$P[X=1 | Y=8] = 0/5/36 = 0$$

+ toto umožňuje podmínit samo seba ~>

$$P[X=l | X=l] \sim \delta_{ll} = \begin{cases} 1 & l=l \\ 0 & l \neq l \end{cases}$$

249
Lemma: Podmíněně rozdělení je opravdu rozdělení.

Dě: ? co vlastně máme ověřit?

- $\forall x \in \mathbb{Z}$ je $P[X=x|Y=l] \geq 0$
- $\sum_{x \in \mathbb{Z}} P[X=x|Y=l] = 1$

Prvé:
$$\left. \begin{array}{l} P[X=x, Y=l] \geq 0 \\ P[Y=l] > 0 \end{array} \right\} \geq 0 \quad \checkmark$$

Druhé:

$$\sum_{x \in \mathbb{Z}} \frac{P[X=x, Y=l]}{P[Y=l]} = \left(\sum_{x \in \mathbb{Z}} P[X=x, Y=l] \right) \cdot \frac{1}{P[Y=l]} =$$

$$= \frac{1}{P[Y=l]} \cdot \underbrace{P[\cup_{x \in \mathbb{Z}} \{X=x\} \cap \{Y=l\}]}_{=1} = \frac{1}{P[Y=l]} P[Y=l] = 1 \quad \checkmark$$

Připomeníme:

$$\text{var}(X+Y) = E((X+Y) - E(X+Y))^2 = \underbrace{\text{var} X}_{E(X-EX)^2} + \underbrace{\text{var} Y}_{E(Y-EY)^2} + \underbrace{2E[(X-EX)(Y-EY)]}_{???}$$

Def: Bud' (X, Y) náhodný vektor takový, že má konečné druhé momenty složek (t.j. $E X^2 < \infty$, $E Y^2 < \infty$).

• Kovariance (znač. $\text{cov}(X, Y)$):

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

• Korelace (znač. $\rho_{X, Y}$)

$$\rho_{X, Y} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var} X \text{var} Y}}$$

- Neuhází sdružené rozdělení, ale alespoň o něm něco dá.
≈ říká, jak se chovají společně / záporné a malé / velké X, Y .

? Proč potřebujeme náh. vektor? \leadsto Abychom měli sdružené rozdělení a uměli spočít. $E(XY)$

Pro CNV:
$$E(XY) = \sum_{r \in \mathbb{Z}} \sum_{s \in \mathbb{Z}} r \cdot s \cdot P[X=r, Y=s]$$

Základní vlastnosti korelace a kovariance:

Věta: Bude (X, Y) náhodný vektor. Pak:

1. Jsou-li X a Y nezávislé, pak $\text{cov}(X, Y) = 0$,
čemuž říkáme, že X a Y jsou NEKORELOVANÉ!

! Z $\text{cov}(X, Y) = 0$ neplyne nezávislost X a Y !

2. $\text{cov}(aX+b, Y) = a \cdot \text{cov}(X, Y)$.

3. $\text{cov}(X+Y, Z) = \text{cov}(X, Z) + \text{cov}(Y, Z)$

Dk: 1.) pro CNV:

$$E(XY) = \sum_r \sum_s rs P[X=r, Y=s] \stackrel{\text{nezávislost}}{=} \sum_r \sum_s rs P[X=r] P[Y=s] =$$

$$= \underbrace{\sum_r r P[X=r]}_{EX} \underbrace{\sum_s s P[Y=s]}_{EY} = EX \cdot EY \Rightarrow \text{cov}(X, Y) = 0$$

! Ale jen 1 směrem!
(Nezávislost není obousměrná!)

Př: $P[X=i] = 1/3, i = -1, 0, 1$
 $Y = X^2$

$$P[X=0, Y=0] = 1/3$$

$$P[X=1, Y=1] = 1/3$$

$$P[X=-1, Y=1] = 1/3$$

$$EXY = 0 \cdot 0 \cdot 1/3 + 1 \cdot 1 \cdot 1/3 + (-1) \cdot 1 \cdot 1/3 = 0 = EX \cdot EY$$

$\Rightarrow EXY - EXEY = 0$, ale nejsou nezávislé!

2.) $\text{cov}(aX+b, Y) = E[(aX+b - E(aX+b)) \cdot (Y - EY)] = E(a(X - EX)(Y - EY)) =$
 $\xrightarrow{aEX+Y} a \cdot E[(X - EX)(Y - EY)]$

3.) obdobně jako 2.)

Pozorování:

- $cov(X, X) = var X \quad \dots \quad E(X - EX)^2 = E[(X - EX)(X - EX)]$
- $var(X + X) = var X + var X + 2cov(X, X) = 4var X \{ = var(2X) \}$
- je-li $cov(X, Y) > 0$, pak $var(X + Y) > var X + var Y$
 < 0 , pak $var(X + Y) < var X + var Y$
- $var(X - Y) = E(X - Y - E(X - Y))^2 = var X - 2cov(X, Y) + var Y > 0$.
- jsou-li X a Y nezávislé, pak $var(X + Y) = var X + var Y$.
- $var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n var X_i + \sum_{i \neq j} cov(X_i, X_j)$
- $cov(X, Y) = cov(Y, X)$.

opaž:

Sdružené a marginální rozdělení:

↳ Podmíněné rozdělení

→ Nezávislost

→ Kovariance, korelace.

(X, Y) CNV

$cov(X, Y) = E[(X - EX)(Y - EY)]$, pokud $EX^2 < \infty, EY^2 < \infty$

Základní vlastnosti:

- $cov(aX + b, Y) = a \cdot cov(X, Y)$
- $cov(X, Y) = cov(Y, X)$
- $cov(X, X) = var X$
- $cov(X + Y, Z) = cov(X, Z) + cov(Y, Z)$
- $cov(a, X) = 0$ (lebo $(a - Ea) = 0$ pe $\forall a \in \mathbb{R}$).

Korelace \equiv normovaná ~~korelace~~ kovariance

$\rho_{X,Y} = \frac{cov(X, Y)}{\sqrt{var X \cdot var Y}} \quad 0 < var X, var Y < \infty$ (≈ aby šlo delit)

Tvrzení: (zákl. vlastn. $\rho_{X,Y}$)

$$\bullet \rho_{aX+b,Y} = \rho_{X,Y} \cdot \operatorname{sgn}(a)$$

$$\bullet \rho_{X,Y} = \rho_{Y,X}$$

$$\bullet \rho_{X,X} = 1$$

$$\bullet |\rho_{X,Y}| \leq 1$$

$$\bullet |\rho_{X,Y}| = 1 \Leftrightarrow \exists a \neq 0, b \in \mathbb{R} : P\{\omega : Y(\omega) = aX(\omega) + b\} = 1$$

+ zjednodušené $P(Y = aX + b) = 1$. (morfimálné)

+ dá sa upresniť $\exists a > 0$ a $\exists a < 0 \Rightarrow$ priama / nepriama úmera.

Viac-menej korelácie \equiv miera (lineárnej) závislosti.

Dk:

$$1. \rho_{aX+b,Y} = \frac{\operatorname{cov}(aX+b,Y)}{\sqrt{\operatorname{var}(aX+b) \operatorname{var} Y}} = \frac{a \cdot \operatorname{cov}(X,Y)}{\sqrt{a^2 \operatorname{var} X \operatorname{var} Y}} = \rho_{X,Y} \cdot \operatorname{sgn}(a)$$

$$2. \text{ (zjavne, } \forall \text{ je symetrické), } 3. \text{ po rozp. def. } = \frac{\operatorname{var} X}{|\operatorname{var} X|} \text{ a } \operatorname{var} X \geq 0$$

$$4. \rho_{X,Y} = \frac{\operatorname{cov}(X,Y)}{\sqrt{\operatorname{var} X \operatorname{var} Y}} = \frac{\sum_{i,j \in \mathbb{Z}} (i - EX)(j - EY) \cdot P[X=i, Y=j]}{\sqrt{\sum_{i \in \mathbb{Z}} (i - EX)^2 P[X=i] \cdot \sum_{j \in \mathbb{Z}} (j - EY)^2 P[Y=j]}}$$

= (ak majú $\forall \sum$ zmysel) \Rightarrow (Cauchy-Schwarz)

$$\begin{aligned} \left(\sum \sum (i - EX)(j - EY) P[X=i, Y=j] \right)^2 &\leq \sum \sum (i - EX)^2 P[X=i, Y=j] \cdot \\ &\cdot \sum \sum (j - EY)^2 P[X=i, Y=j] = \sum_i (i - EX)^2 P[X=i] = \operatorname{var} X \\ &= \sum_j (j - EY)^2 P[Y=j] = \operatorname{var} Y \end{aligned}$$

$$5. (\rho_{X,Y} = 1) \Leftrightarrow \exists a, b : Y = aX + b. \quad (\Leftarrow)$$

Nechť $Y = aX + b$.

$$\text{pať} \cdot \operatorname{cov}(X, Y) = \operatorname{cov}(X, aX + b) = a \cdot \operatorname{cov}(X, X)$$

$$\bullet \operatorname{var} Y = \operatorname{var}(aX + b) = a^2 \cdot \operatorname{var}(X)$$

$$\Rightarrow \rho_{X,Y} = \frac{a \cdot \operatorname{cov}(X, X)}{\sqrt{a^2 (\operatorname{var} X)^2}} = \frac{a}{|a|} = \operatorname{sgn}(a)$$

Necht $\rho_{X,Y} = 1$

(\Rightarrow)

vezmeme matici

$$\begin{pmatrix} \text{var } X & \text{cov}(X,Y) \\ \text{cov}(X,Y) & \text{var } Y \end{pmatrix} = \begin{pmatrix} \text{var } X & \sqrt{\text{var } X \text{ var } Y} \\ \sqrt{\text{var } X \text{ var } Y} & \text{var } Y \end{pmatrix}$$

\leadsto determinant: $0 \Rightarrow$ singularni \Rightarrow 1 riadoš lin. komb. 2.

(~~HA~~ ~~var~~ ~~X~~ ~~=~~ ~~var~~ ~~Y~~ ~~·~~ ~~koeficient~~ ~~AN~~)

resp. \exists konstanty c, d takové, že $(c, d) \neq (0, 0)$.

$$(c, d) \begin{pmatrix} \text{var } X & \text{cov}(X,Y) \\ \text{cov}(X,Y) & \text{var } Y \end{pmatrix} \begin{pmatrix} c \\ d \end{pmatrix} = 0.$$

$$\Rightarrow c^2 \text{var } X + 2cd \text{cov}(X,Y) + d^2 \text{var } Y = \text{var}(cX + dY) = 0$$

\leadsto je-li rozptyl náh. veličiny 0, pak je tato veličina

konstantní (s Pravděj. 1) $\Rightarrow \exists \xi: cX + dY = \xi$

$$\Rightarrow Y = aX + b$$

Podmíněná střední hodnota

(X, Y) CNV podm. za podmínky $Y=j$

$$P[X=i | Y=j] = \frac{P[X=i, Y=j]}{P[Y=j]} \quad i \in \mathbb{R} \quad \text{je-li } P[Y=j] > 0.$$

Def. Bud (X, Y) CNV, pro ~~ž~~ které existuje EX. Def.

$$E[X | Y=j] = \sum_{i \in \mathbb{Z}} i \cdot P[X=i | Y=j], \quad \text{požad. } P[Y=j] > 0.$$

Věta: (vztah EX a $E[X | Y=j]$):

Necht (X, Y) CNV, EX existuje & $< \infty$. Pak

$$EX = \sum_{j \in J} P[Y=j] E[X | Y=j], \quad \text{sde}$$

J je množina těch j, pro něž $P[Y=j] > 0$.

Dě: výpočet:

$$EX = \sum_i i \cdot P[X=i]$$

$$P[X=i] = \sum_j P[X=i, Y=j] = \sum_j P[X=i|Y=j] \cdot P[Y=j]$$


$$EX = \sum_i i \sum_j P[X=i|Y=j] P[Y=j] = \sum_{j \in J} P[Y=j] \sum_i i P[X=i|Y=j] = \sum_{j \in J} P[Y=j] E[X|Y=j]$$

Pr:

výpočet V , št. spustíme a on n V svím púbehom volá X -krát sebe, kde X jsou nezávislé nah. veličiny,

po mě $P[X=k] = \binom{n}{k} p^k (1-p)^{n-k}$ (Binom. rozděl.)
 $k = 0, 1, \dots, n$

? Jaky je střední počet spuštěných výpočtů n ?



y_i = počet n i -úrovní
 $E y_i$ nie je jednoduché spočítat, ale dá sa učit $E[y_3|y_2=j]$

$y_m \dots$ jaky je $E[y_m | y_{m-1} = X_{m-1}] = ?$

$$E[y_m | y_{m-1} = X_{m-1}] = \sum_i i P[y_m = i | y_{m-1} = X_{m-1}]$$

$$+ \text{☺} E y_1 = \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} = np$$

↳ # procesů 0 1 ↑

X_{m-1} je skutečný: \rightsquigarrow Podmínka říká, že y_{m-1} NENÍ v TUTO CHVÍLI NAHODNĚ, ale jde o průměr $\bar{o} \approx X_{m-1}$

$$\Rightarrow = \sum_{i=0}^{m \cdot X_{m-1}} i \cdot P\left[\sum_{j=1}^{X_{m-1}} z_j = i \mid Y_{m-1} = X_{m-1}\right]$$

gde z_j jsou nezávislé náh. veličiny s rozdělením
 $P[z_j = k] = \binom{m}{k} p^k (1-p)^{m-k}$ pro $k = 0, 1, \dots, m$.

+ jestli z_j jsou nezávislé a Y_{m-1} } podmíněná pravděp.
 \sum starších z_j se stává ne podmíněnou

$$E[Y_m \mid Y_{m-1} = X_{m-1}] = \sum_{i=0}^{m X_{m-1}} i \cdot P\left[\sum_{j=1}^{X_{m-1}} z_j = i\right] = E\left(\sum_{j=1}^{X_{m-1}} z_j\right) =$$

$$= \sum_{j=1}^{X_{m-1}} E z_j = \underline{X_{m-1} \cdot m \cdot p}$$

$$\text{Počítáme } E Y_m = \sum_j P[Y_{m-1} = j] \cdot E[Y_m \mid Y_{m-1} = j] = \sum_j P[Y_{m-1} = j] \cdot j \cdot m p =$$

$$= m p \sum_j j P[Y_{m-1} = j] = m p E Y_{m-1} = m p \cdot m p E Y_{m-2} = \dots = (m p)^m$$

↑
m rovň
w rozdelemí

$$\sum_{k=0}^{\infty} (m p)^k \dots \quad m p < 1 \quad 1/(1 - m p)$$

$$m p \geq 1 \quad \infty$$

$$\text{Opažova'mi: } E[X \mid Y=y] = \sum_k k P[Y=k \mid Y=y]$$

X, Y nezávislé $\Rightarrow E[X \mid Y=y] = E[X]$.

$$P[X=x \mid Y=y] = P[X=x] \quad \forall x, y \Leftrightarrow X, Y \text{ nezávislé}$$

$$E[X \mid Y=y] = E[X] \quad \forall y \Leftrightarrow X, Y \text{ nezávislé}$$

Všimneme si, že $E[X \mid Y=y]$ je funkcí y

Def: $E[X \mid Y]$ je náhodná veličina, kt. na množině
 $\{\omega: Y(\omega) = y\}$ má yrovň hodnoty $E[X \mid Y=y]$

Tedy $E[X \mid Y]: \Omega \rightarrow \mathbb{R}$ náh. veličina

$$E[X \mid Y](\omega) = E[X \mid Y=y] \text{ pokud } Y(\omega) = y$$

$$E[X \mid Y] = f(Y) \text{ po měřáku } f: \mathbb{R} \rightarrow \mathbb{R}$$

Věta: $E[E[X|Y]] = EX$, mají-li obě strany smysl.

$$\begin{aligned} \text{Dk: } E(E[X|Y]) &= E f(Y) = \sum_{\xi} f(\xi) P[Y=\xi] = \sum_{\xi} E[X|Y=\xi] P[Y=\xi] \\ &= EX, \text{ mž věta z min přednášky.} \end{aligned}$$

Modely Rozdělení Diskrétních Náh. Velic:

1. Alternativní rozdělení: (Alt(p))

Bernoulliho pokus:

neúspěch úspěch

N.V. X nabývá pouze 2 hodnot $X \in \{0, 1\}$

$$P[X=1] = p \quad \text{pro parameter } p \in (0, 1)$$

$$P[X=0] = 1-p$$

$$EX = p$$

$$EX^2 = p$$

$$\Rightarrow \text{var } X = p - p^2 = p(1-p)$$

2. Binomické rozdělení (Bi(m, p))

• Začneme opakovat (nezávislé) bernoulliho pokusy

• Dostaneme posloupnost 0 a 1. \Rightarrow 0101101

$$(1-p)^k p (1-p)^{m-k} p$$

\Rightarrow Otázka \sim Jaký je počet 1? (úspěchů v m pokusech)

$$Y = \sum_{i=1}^m X_i = \text{počet úspěchů}$$

$$P[Y=k] = \binom{m}{k} p^k (1-p)^{m-k} \quad \dots \text{BINOMICKÉ ROZDĚLENÍ.}$$

$$\left(\text{pozn. } 1 = (p + (1-p))^m = \sum_{i=0}^m \binom{m}{i} p^i (1-p)^{m-i} \right)$$

$$EY = mp$$

$$\text{var } Y = mp(1-p)$$

3. Geometrické rozdělení (Geom(p))

$$EY = \frac{1-p}{p}$$

... Rozdělení čekání na 1. úspěch

X_1, X_2, X_3, \dots nezávislé n.v. ~~Alternující~~ Alt(p)

$$Y = \min \{i : X_i = 1\} - 1$$

$$P[Y=k] = (1-p)^k \cdot p \quad k = 0, 1, 2, \dots$$

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

4. Negativně binomické NB(λ, p)

$$EY = \lambda \cdot \frac{1-p}{p}$$

neúspěchů před λ -tým úspěchem

$$Y = \sum_{i=1}^k Y_i, \text{ kde } Y_i \text{ jsou nezávislé m.v. Geom.}(p)$$

$$P[Y=j] = \binom{j+k-1}{j} (1-p)^j p^k \quad \rightsquigarrow \quad j \times 0, \quad \lambda \times 1, \quad j+k \text{ pokusů}$$

U binomického rozdělení známe předem # pokusů a neznámej je # úspěchů.

U neg. binom. máme, kolik bude úspěchů ale náhodný je počet pokusů

5. Poissonovo rozdělení Po(λ)

$$EY = \lambda \quad (= \lim m p_m)$$

$$\text{var } Y = \lambda \quad (= \lim m p_m (1-p_m))$$

mějme Bi(m, p_m) tak, že $m p_m \rightarrow \lambda > 0$

motivace: 1 atom, za určitou dobu se rozpadne s p & počítáme, kolik se rozpadne za $1/k$ sekundy (na zač. m)

$$P(X_m = k) = \binom{m}{k} p_m^k (1-p_m)^{m-k}$$

$$\frac{m!}{(m-k)! k!} \cdot p_m^k \cdot (1-p_m)^{m-k} = \frac{m \cdot (m-1) \cdot \dots \cdot (m-k+1)}{k!} p_m^k \cdot (1-p_m)^m \cdot (1-p_m)^{-k} =$$

\Rightarrow pozor. k permutace } jestliže $m p_m \rightarrow \lambda \Rightarrow p_m \rightarrow 0 \Rightarrow$

$$= \frac{1}{k!} \left[\frac{m}{m} \cdot \frac{(m-1)}{m} \cdot \dots \cdot \frac{m-k+1}{m} \right] \left[m^k \cdot p_m^k \right] \cdot \left(1 - \frac{\lambda}{m}\right)^m \cdot \left(\frac{1-p_m}{1 - \frac{\lambda}{m}}\right) \cdot (1-p_m)^m$$


\downarrow \downarrow \downarrow \downarrow \downarrow
 1 λ^k $e^{-\lambda}$ 1 1

$$\Rightarrow P[X_m = k] \rightarrow e^{-\lambda} \frac{\lambda^k}{k!} \quad \text{pro } k = 1, 2, \dots$$

$$P(Y = k) = e^{-\lambda} \frac{\lambda^k}{k!} \Rightarrow Y \text{ má Poissonovo rozdělení } Po(\lambda)$$

6. Hypergeometrické rozdělení

~> Binomické (s racionálním p) $p = M/N$



l bílých (úspěchů) $m-l$ černých (neúspěch) + vytahujeme a vždy vrátíme & zamícháme.

~> Hypergeometrické ~> nevracíme:

N míčků, M bílých a vytáhneme n míčků, bez vracení.

X je počet vytážených bílých míčků.

$$P(X=k) = \frac{\text{priznave}}{\text{všechny}} = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}} \quad 0 \leq k \leq n$$

$$0 \leq k \leq M$$

$$0 \leq n-k \leq N-M$$

Požad $N \rightarrow \infty$, $\frac{M}{N} \rightarrow p \in (0,1)$ a n je konstantní,

paž

$$P(X=k) \rightarrow \binom{n}{k} p^k (1-p)^{n-k}$$

$$EX = n \cdot \frac{M}{N}$$

jde k binom. rozdělení.

Rozdělení máh. vektorů:

7. Multinomické rozdělení:

Základ: obecné rozdělení s více možnými výsledky.

k možných výsledků $\{a_1, \dots, a_k\}$

$$P(X_i = a_j) = p_j, \text{ kde } p_j > 0 \text{ a } \sum_{j=1}^k p_j = 1$$

~> máh. vektor $Y = (Y_1, \dots, Y_k)$

Zavedme $Z_i = (Z_{i1}, \dots, Z_{ik})$, kde $Z_{ij} = 1 \Leftrightarrow X_i = a_j$ (jinak 0)

$$Y = \sum_{i=1}^n Z_i \quad \text{vždy platí } Y_k = n - \sum_{j=1}^{k-1} Y_j$$

$$P[Y = (m_1, \dots, m_k)] = \frac{n!}{m_1! m_2! \dots m_k!} p_1^{m_1} p_2^{m_2} \dots p_k^{m_k}$$

pro $\forall (m_1, \dots, m_k)$ zároveň, že $m_i \geq 0$ a $\sum_{j=1}^k m_j = n$

Y_j má $B_i(n, p_j) \Rightarrow$

$$\begin{aligned} E Y_j &= n p_j \\ \text{Var } Y_j &= n p_j (1-p_j) \\ \text{cov}(Y_i, Y_j) &= -n p_i p_j \end{aligned}$$

Zobecnění Hypergeometrického

N koulí

M_i koulí barvy i : $\sum_{i=1}^k M_i = N$

m koulí vytáhn. bez vracení

$$P(Y = (m_1, \dots, m_k)) = \frac{\binom{M_1}{m_1} \dots \binom{M_k}{m_k}}{\binom{N}{m}}$$

↓ #vytaž. barvy i

Spojité náhodné veličiny a vektory:

X nabývá hodnoty v nějakém otevřeném intervalu / sjednocení otevřených intervalů.

Def: (Absolutně spojitá náh. velič.)

Náh. veličina $X: (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B})$ (kde \mathcal{B} je σ -algebra obsahující \mathbb{R} otevřené intervaly (borelovská σ -algebra))

se nazývá absolutně spojitá, existuje-li mězajorní funkce

$f: \mathbb{R} \rightarrow [0, \infty)$ taková, že $P[X \leq x] = \int_{-\infty}^x f(x) dx$.

Pozn. + jistě musí platit $\int_{-\infty}^{\infty} f(x) dx = 1$

Př: $f(x) = 1 \quad x \in (0, 1)$
 $= 0 \quad x \notin (0, 1)$

$$\Rightarrow P[X \leq x] = \int_0^x 1 dx = x \quad \text{po } x \in (0, 1)$$

$$= 0 \quad \text{po } x \leq 0 \quad \leadsto \text{distribuční funkce}$$

$$= 1 \quad \text{po } x \geq 1$$

Def: Absolutně sp. m.v. je taková, jejíž distrib. funkce je integrálem nějaké mězajorní funkce, tedy platí:

$$F_x(x) = \int_{-\infty}^x f_x(x) dx$$

a pro „skoro všude“ x platí $F_x(x) = \frac{d}{dx} F_x(x) = f_x(x)$

\hookrightarrow derivace, derivace podle x

+ funkci f_x říkáme HUSTOTA ROZDĚLENÍ X .

... a skoro všude \approx je somečně mnoho \equiv mjnimem.

$$f_X(x) = 1, \quad x \in (0,1)$$

$$= 0 \quad \text{jinač}$$


$$P(X \in (a,b)) = b-a$$

= délka intervalu.

• Skriptá: Zvařa Štěpán:
Pravděpodobnost a statistika.

• \int funkce, kt. nejde zapsat jako
integrál $\Rightarrow \int$ jiné definice.

pro obecnou f_X :



$$P(X \in (a,b)) = \int_a^b f_X(x) dx.$$

+ Pro „skoro všechny“ body x tedy platí:

$$f_X(x) = \lim_{h \rightarrow 0^+} \frac{P(X \in [x, x+h])}{h}$$

ABSOLUTNĚ SPOJITÝ NÁH. VEKTOR:

Def: Náhodný vektor $X = (X_1, \dots, X_d)$ je absolutně spojité, existuje-li
mezaj. funkce $f_X: \mathbb{R}^d \rightarrow \mathbb{R}$ takové, že

$$F_X(x_1, \dots, x_d) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_d} f_X(t_1, t_2, \dots, t_d) dt_d dt_{d-1} \dots dt_1.$$

! X abs. spoj. náh. vektor (x_1, \dots, x_d) má abs. spojité složky, ale není
abs. spoj. náh. vektor!

Marginální distr. funkce:

$$F_{X_1}(x_1) = \lim_{x_2 \rightarrow \infty, \dots, x_d \rightarrow \infty} F_X(x_1, \dots, x_d) = \int_{-\infty}^{x_1} \left(\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_X(t_1, \dots, t_d) dt_d \dots dt_2 \right) dt_1$$

$$= \int_{-\infty}^{x_1} f_{X_1}(t_1) dt_1 \quad \dots \quad \text{opět uvolněme } t \text{ složky odrem 1.}$$

$$\Rightarrow f_{X_1}(x_1) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_X(x_1, t_2, \dots, t_d) dt_d \dots dt_2$$

$d-1$ integrálů

$\leadsto f_{X_1}$ je MARGINÁLNÍ = HUSTOTA.

Def: Marginální hustota $f_{X_1, \dots, X_k}(x_1, \dots, x_k) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_X(x_1, \dots, x_k, t_1, \dots, t_d) dt_1 \dots dt_d$

~~Pozn:~~ d-k int.

Rozdělení abs. spoj. n. vekt. je dáno jednoznačně hustotou

Pozn. Náhodný vektor může sdružovat abs. spojité a diskrétní složky. Potom je obvykle složitější zápis jeho rozdělení.

Absolutně spojité náh. vektor má nezávislé složky $\Leftrightarrow f_X(x_1, \dots, x_d) = \prod_{i=1}^d f_{X_i}(x_i) \quad \forall (x_1, \dots, x_d) \in \mathbb{R}^d$

Def:

Pro absolutně spojité náh. vektor X definujeme

$$E\varphi(X) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \varphi(x_1, \dots, x_d) f_X(x_1, \dots, x_d) dx_1 \dots dx_d$$

ma', li integrál napravo smysl, a $\varphi: \mathbb{R}^d \rightarrow \mathbb{R}$ (φ je funkce náh. vektoru)

Pozn.

Koreštní definice: $E\varphi(X) = \int_{\Omega} \varphi(X(\omega)) \cdot P(d\omega)$

Příklady φ : 1. $\varphi(x) = x_1$

$$EX_1 = E\varphi(X) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} x_1 f_X(x_1, \dots, x_d) dx_d \dots dx_1 =$$

$$= \int_{-\infty}^{\infty} x_1 \left(\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_X(x_1, x_2, \dots, x_d) dx_d \dots dx_2 \right) dx_1 = \int_{-\infty}^{\infty} x_1 f_{X_1}(x_1) dx_1$$

2. $\varphi(x) = (x_1 - EX_1)^2 \rightsquigarrow E\varphi(X) = E(x_1 - EX_1)^2 = \text{var } X_1$

3. $\varphi(x) = (x_1 - EX_1)(x_2 - EX_2) \rightsquigarrow E\varphi(X) = \text{cov}(X_1, X_2)$

Příklady rozdělení abs. spoj. náh. veličin:

1. ROVNOMĚRNĚ ROZDĚLENÍ:


• Ramečný interval (a, b) : $a < b$. + Hustota musí být konstantní.

$$\Rightarrow f_X = \frac{1}{b-a} \quad (\text{aby } \int_a^b f(x) dx = 1)$$

$$EX = \frac{a+b}{2}$$
$$\text{var } X = \frac{(b-a)^2}{12}$$


• Používá se jako „neinformativní rozdělení“
• „zaokrouhlovací chyba“ : $\xrightarrow{\text{2.str.}}$

X změříme s přesností na cm. „skutečně“ X má rovnoměrné rozdělení na int. $(x - \frac{\Delta}{2}, x + \frac{\Delta}{2})$



1. EXPONENCIÁLNÍ ROZDĚLENÍ

- je dáno hustotou $f_X(x) = \lambda e^{-\lambda x} \quad x > 0$
 $= 0 \quad x \leq 0$



$$EX = 1/\lambda$$

$$\text{var } X = 1/\lambda^2$$

→ Zařadíme rozdělení pro modelování
 „doby mezi událostmi“

+ je to ROZDĚLENÍ BEZ PAMĚTI: $P(X > x+y | X > y) = P(X > y) =$
 \rightarrow reálně ve vědy odpovídá sřut. $[= P(X > y | X > 0).$

3. GAMA ROZDĚLENÍ

$$f_X(x) = \frac{\lambda^m x^{m-1} e^{-\lambda x}}{(m-1)!} \quad x > 0$$

- $\lambda > 0$ je PARAMETR, $m \in \mathbb{N}$ je také parametr.
- Vezmeme-li m nezávislých máh. veličin s rozdělením $\text{Exp}(\lambda)$ pak jejich součet má Gama (n, λ) :

$$EX = \frac{m}{\lambda}$$

$$\text{var } X = \frac{m}{\lambda^2}$$

• Pro $m \in \mathbb{R}$ $f_X(x) = \frac{\lambda^m x^{m-1} e^{-\lambda x}}{\Gamma(m)}$, kde $\Gamma(m) = \int_{-\infty}^{\infty} x^{m-1} e^{-x} dx$

je GAMA FUNKCE: $m \in \mathbb{N} \quad \Gamma(m) = (m-1)!$


$$\forall m \quad \Gamma(m) = (m-1) \Gamma(m-1)$$

(zobecnění faktoriálu).

4. NORMÁLNÍ (GAUSSOVO) ROZDĚLENÍ

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\} \quad x \in \mathbb{R}$$

$\mu \in \mathbb{R}$ param.
 $\sigma > 0$ param.



menší $\sigma \Rightarrow$ užší (Ω)

větší $\sigma \Rightarrow$ širší (\sim)

$EX = \mu$
$\text{var } X = \sigma^2$

5. NORMOVANÉ NORMÁLNÍ ROZDĚLENÍ

$$f_Z(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \quad x \in \mathbb{R} \quad \sigma^2 = 1$$

$\mu = 0$

$N(0, 1)$

Z má $N(0, 1)$

$X = \sigma Z + \mu$ má právě rozdělení $N(\mu, \sigma^2)$ s hustotou f_X gaussova rozdělení.

6. STANDARDIZOVANÉ DVOUROZMĚRNÉ NORMÁLNÍ

$N_2(0, I_2) =$ (napr.) $N_2\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}\right)$ má hustotu

$$f_Z = \frac{1}{2\pi} \exp\left\{-\frac{x_1^2 + x_2^2}{2}\right\} \quad (x_1, x_2) \in \mathbb{R}^2$$

jde o součin 2 $N(0, 1)$ hustot \boxtimes

$Z = (z_1, z_2)$; z_1, z_2 mají $N(0, 1)$ rozdělení a jsou nezávislé.

A matice 2×2 s hodnotami 2, b vektor $z \in \mathbb{R}^2$. $Az + b$ má obecné dvourozměrné rozdělení $N(b, AA^T)$.

\rightarrow Hustota $N_2(\mu, \Sigma)$: $f_X(x_1, x_2) = \frac{1}{2\pi(\det \Sigma)^{1/2}} \cdot \exp\left\{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)\right\}$

1.12.15/4
8.12.15/1

PAS

Pozor: $\Sigma = \begin{pmatrix} \tilde{\sigma}_{11} & \tilde{\sigma}_{12} \\ \tilde{\sigma}_{12} & \tilde{\sigma}_{22} \end{pmatrix}$ $\left. \begin{array}{l} X_1 \text{ má } N(\mu_1, \tilde{\sigma}_{11}) \\ X_2 \text{ má } N(\mu_2, \tilde{\sigma}_{22}) \end{array} \right\} \text{COV}(X_1, X_2) = \tilde{\sigma}_{12}$

MARGINÁLNÍ ROZDĚLENÍ JE OPĚT NORMÁLNÍ.

Hustota normovaného normálního rozdělení

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \quad x \in \mathbb{R}$$

Distribuční funkce:

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt$$

SOUČTY NEZÁVISLÝCH NÁHODNÝCH VELIČIN:

? Proč se zajímat o součty?

$\bar{X}_m = \frac{1}{m} \sum_{i=1}^m X_i$; X_i jsou nezávislé a stejně rozdělené n.v.

↑ jde o náhodnou veličinu

- Paralela ke střední hodnotě:

EX - teor. stř. hodnota

\bar{X}_m - můžeme spočítat z pozorování. Pro $m \rightarrow \infty$ $\bar{X}_m \rightarrow EX$.

Věta (rozdělení součtu 2 nezávislých náh. veličin.)

1. Buďte X, Y celoč. náh. velič. Pak $Z = X + Y$ je CNV a platí:


$$P[Z = z] = \sum_{m=-\infty}^{\infty} P[X = m] P[Y = z - m]$$

2. Buďte X, Y nezávislé absolutně spojité náh. veličiny, pak

$Z = X + Y$ je absolutně spojita n.v. a platí:

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

Dk. 2.) Víme $F_Z(u) = \int_{-\infty}^u f_Z(z) dz$



$$F_Z(u) = P(X+Y \leq u) = \iint_{\{x,y: x+y \leq u\}} f_X(x) f_Y(y) dy dx =$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{u-x} f_X(x) f_Y(y) dy dx = \int_{-\infty}^{\infty} \int_{-\infty}^u f_X(x) f_Y(z-x) dz dx =$$

↑ substituce

$$y = z - x$$

↖ můžeme přehodit integrály
podle nejvyšší vetvy.

$$= \int_{-\infty}^u \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx dz = \int_{-\infty}^u f_Z(z) dz \quad \square$$

$$f_Z(z)$$

Pr: X má hustotu $f_X(x) = \lambda e^{-\lambda x}$ ~~$x > 0$~~ $x > 0$ } a jsou
 Y má hustotu $f_Y(y) = \lambda e^{-\lambda y}$ $y > 0$ } nezávislé!

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx = \int_0^z \lambda e^{-\lambda x} \lambda e^{-\lambda(z-x)} dx =$$

$$= \lambda^2 \int_0^z e^{-\lambda z} dx = \boxed{\lambda^2 \cdot z \cdot e^{-\lambda z}} \rightarrow \text{hustota gama rozdělení}$$

s parametry $(2, \lambda)$

Pozn.

1. Součet diskrétní a absol. spojité m.v. je absolutně spojitá m.v.

2. Obdobně lze odvodit i rozdělení součinnu 2 nezávislých m.v.
 \rightarrow problém se známkou $\Rightarrow P[X > 0] = P[Y > 0] = 1$ a ok.

$$z = XY$$

$$\text{velocis: } P[z=z] = \sum_{x=1}^{\infty} P[X=x] \cdot P[Y=\frac{z}{x}]$$

$$\text{abs. spoj: } f_Z(z) = \int_0^{\infty} f_X(x) f_Y\left(\frac{z}{x}\right) dx.$$

ČEBYŠEVOVA NEROVNOST

- Obecným způsobem a využitím rozptylu odhadneme pravděpodobnost odchylky náh. veličiny od její stří. hodnoty

Věta (Č.N.)

Bud' X náhodná veličina s konečnou střední hodnotou EX .

Pak

$$P[|X-EX| > \varepsilon] \leq \frac{\text{var } X}{\varepsilon^2} \quad \forall \varepsilon > 0.$$

$$\begin{aligned} \underline{\text{Dk}} \quad P[|X-EX| > \varepsilon] &= P\left[\frac{|X-EX|}{\varepsilon} > 1\right] = P\left[\frac{(X-EX)^2}{\varepsilon^2} > 1\right] = \\ &= (\text{abs. spojitá, celoč. má součet}) \int_{\{X: \frac{(X-EX)^2}{\varepsilon^2} > 1\}} f(x) dx < \int_{\{X: \frac{(X-EX)^2}{\varepsilon^2} > 1\}} \frac{(X-EX)^2}{\varepsilon^2} f(x) dx \\ &\quad \sum P[X=x] \text{ a vyjde stejně.} \quad \{X: \frac{(X-EX)^2}{\varepsilon^2} > 1\} = \{X: \frac{(X-EX)^2}{\varepsilon^2} > 1\} \\ &\leq \int_{-\infty}^{\infty} \frac{(X-EX)^2}{\varepsilon^2} f(x) dx = \frac{1}{\varepsilon^2} \int_{-\infty}^{\infty} (X-EX)^2 f(x) dx = \frac{E(X-EX)^2}{\varepsilon^2} = \\ &= \frac{\text{var } X}{\varepsilon^2} \end{aligned}$$

(slabý) zákon velkých čísel:

$$\text{Vezměme si } Y = \frac{1}{n} \sum_{i=1}^n X_i \quad (= \bar{X}_n)$$

$$\bullet \underline{EY} = E \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} \sum_{i=1}^n EX_i \quad \text{a jsou-li } X_i \text{ nezávislé \& stejné}$$

$$\Rightarrow EX_i = EX_1 \cdot V_i \Rightarrow EY = EX_1$$

$$\bullet \underline{\text{var } Y} = \text{var} \left(\frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \text{var} \left(\sum_{i=1}^n X_i \right) = \frac{1}{n^2} \left(\sum_{i=1}^n \text{var } X_i + \sum_{i \neq j} \text{cov}(X_i, X_j) \right)$$

$$= \frac{1}{n} \cdot \text{var } X_1 \quad \text{var } X_1 \quad 0$$

Věta: (Čebyševův (slabý) zákon velkých čísel)

Jsou-li X_1, \dots, X_n ~~nezávislé~~ ~~stejně~~ ~~rozdělené~~ n.v. s konečným rozptylem ($\text{var } X_i < \infty$), ~~platí~~ a $EX_i = \mu$, pak:

$$P[|\bar{X}_n - \mu| < \varepsilon] \xrightarrow{n \rightarrow \infty} 1 \quad \forall \varepsilon > 0.$$

Dk: Označíme $Y = \bar{X}_n$. Z Čebyševovy nerovnosti plyne
 $P[|Y - EY| > \varepsilon] = P[|Y - \mu| > \varepsilon] < \frac{\text{var } Y}{\varepsilon^2} = \frac{1}{n} \frac{\text{var } X_1}{\varepsilon^2} \xrightarrow{n \rightarrow \infty} 0.$

Pr: Budte X_1, \dots, X_n ~~nezávislé~~ $\text{alt}(p)$

$$P[X=1] = p = 1 - P[X=0].$$

$\frac{1}{n} \sum_{i=1}^n X_i$ = podíl úspěchů v n pokusech.

$$EX = p, \quad \text{var } X = p(1-p).$$

$$P\left[\left|\frac{1}{n} \sum_{i=1}^n X_i - p\right| > \varepsilon\right] \xrightarrow{n \rightarrow \infty} 0 \quad \forall \varepsilon > 0.$$

Také píšeme $\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} p$... konverguje v pravděpodobnosti.

Pozor: ~~platí~~: Někdo se domnívá, že platí $(\sum_{i=1}^n X_i - np) \xrightarrow{P} 0$,
ale TO NENÍ PRAVDA!

(např. ať padl 3x ~~rub~~, není myšl. pravděp., že padne líc).

Def: Posloupnost X_1, X_2, \dots náhodných veličin splňuje slabý zákon velkých čísel, existuje-li konstanta b (konečná) taková, že

$$P\left[\left|\frac{1}{n} \sum_{i=1}^n X_i - b\right| > \varepsilon\right] \xrightarrow{n \rightarrow \infty} 0.$$

Podle Čeb. zákona tedy posloupnost nezávisle a stejně rozdělených n.v. s $\text{var } X < \infty$ splňuje ZVČ, kde $b = EX_1$.

$X_1 \dots$ takové, že $\frac{1}{n} \sum_{i=1}^n EX_i \rightarrow b$

nezávislé $\frac{1}{n^2} \sum_{i=1}^n \text{var } X_i \rightarrow 0$

podle č. N. opět $P\left[\left|\frac{1}{n} \sum_{i=1}^n X_i - b\right| > \varepsilon\right] \xrightarrow{n \rightarrow \infty} 0$.


Protože $\text{var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{var } X_i + \frac{1}{n^2} \sum_{i \neq j} \text{cov}(X_i, X_j)$,

pokud $\text{var } X_i \leq K \quad \forall_i$ a pokud $\frac{1}{n^2} \sum_{i \neq j} \text{cov}(X_i, X_j) \rightarrow 0$,
~~pak~~ a $\frac{1}{n} \sum_{i=1}^n EX_i \rightarrow b$, pak $\{X_i\}_{i=1}^{\infty}$ také splňuje ZVČ.

Pr: $P[X_i = 1] = \frac{1}{2} = P[X_i = -1]$

$P[X_i = 1 \text{ po } 5_i \text{ a } X_i = -1 \text{ po } 0_i] = \frac{1}{25} = \frac{1}{32}$

$\frac{1}{n} \sum_{i=1}^n X_i = \sum \frac{X_i}{n} \xrightarrow{P} 0$



CENTRÁLNÍ LIMITNÍ VĚTA

? Co říká ZVČ? \rightarrow Pokud jsou X_i nezávislé, st. rozdělené,
 $EX_i = \mu \quad \text{var } X_i = \sigma^2 < \infty$, pak $\frac{1}{n} \sum_{i=1}^n (X_i - \mu) \xrightarrow{P} 0$.

? Co když vezmeme jen $\frac{1}{\sqrt{n}}$? (Uvažuj se, že n limitě konverg. k $\Phi(x)$)

Věta: (CLV): Budeť X_1, X_2, \dots nezávislé, stejně rozdělené
 n.v., $EX_i = \mu$, $0 < \text{var } X_i = \sigma^2 < \infty$, PAK:

$$P\left[\frac{1}{\sqrt{n}} \cdot \frac{\sum_{i=1}^n (X_i - \mu)}{\sigma} \leq x\right] \rightarrow \Phi(x)$$

pro $\forall x \in \mathbb{R}$ (stejněměrně).

Distrib. fce $N(0,1)$

Distribucni' funkcije m.v.

$$Z = \frac{\sum X_i - m\mu}{\sqrt{m\sigma^2}} \text{ konvergira } \mathcal{E} \text{ d.f. } N(0,1).$$

X_1, \dots, X_m nezavisle' $N(0,1)$

$$EX_1 = 0 \Rightarrow \frac{1}{\sqrt{m}} \sum_{i=1}^m X_i \text{ ma' opet } N(0,1)$$

var $X_1 = 1$

$$\frac{\sum_{i=1}^m X_i - m \cdot 0}{\sqrt{m \cdot 1}} = \frac{1}{\sqrt{m}} \sum_{i=1}^m \frac{X_i - 0}{\sqrt{1}}$$

Jine' formy CLV:

$$P\left[\frac{1}{\sqrt{m}} \cdot \sum_{i=1}^m \frac{(X_i - \mu)}{\sqrt{\sigma^2}} \leq x\right] \rightarrow \Phi(x)$$

$$P\left[\sqrt{m} \cdot \frac{(\bar{X}_m - \mu)}{\sqrt{\sigma^2}} \leq x\right] = P\left[\frac{1}{\sqrt{m}} \left(\sum_{i=1}^m (X_i - \mu)\right) \leq x\sqrt{\sigma^2}\right] \rightarrow \Phi(x)$$

X_i alt(p); $EX_i = p$; var $X_i = p(1-p)$

$$P\left[\sqrt{m} \frac{(\bar{X}_m - p)}{\sqrt{p \cdot (1-p)}} \leq x\right] \rightarrow \Phi(x)$$

$$P\left[(\bar{X}_m - p) \leq x \cdot \sqrt{\frac{p(1-p)}{m}}\right] \rightarrow \Phi(x)$$

$$\Phi(1,96) = 0,975$$

$$P\left[|\bar{X}_m - p| \leq 1,96 \cdot \sqrt{\frac{p(1-p)}{m}}\right] = \cancel{0,975} \cdot 2 = 0,95, \text{ dvoji abs. hodnote} \Rightarrow \cancel{0,975}^2$$

ZVC: X_1, X_2, \dots mezovislé & stejné rozdělení


$$\bar{X}_n = \frac{1}{n} \sum X_i \xrightarrow{P} EX \quad \text{pokud } \text{var } X_i < \infty$$

$$P\left(\left|\frac{1}{n} \sum X_i - \frac{1}{n} \sum EX_i\right| \geq \varepsilon\right) \leq \frac{\text{var}\left(\frac{1}{n} \sum X_i\right)}{\varepsilon^2}$$

CLV:Pokud X_1, X_2, \dots mez. & st. rozdel. $0 < \text{var } X_i < \infty, EX_i = \mu,$

$$P\left(\sqrt{n} \frac{\bar{X}_n - \mu}{\sqrt{\sigma^2}} \leq x\right) \rightarrow \Phi(x), \text{ resp. } \sqrt{n} \frac{(\bar{X}_n - \mu)}{\sqrt{\sigma^2}} \xrightarrow{D} N(0,1)$$

! zvc metricki $|\sum X_i - m\mu| \xrightarrow{P} 0$, ale $\left|\frac{1}{n} \sum X_i - EX\right| \xrightarrow{P} 0$.
 "v distribuci"

 $\Phi(x)$:

$$-1,645 \rightsquigarrow 0,05 \quad 1,645 \rightsquigarrow 0,95$$

$$P\left(|\sum X_i - mEX_i| \leq \sqrt{m\sigma^2} x\right) \rightarrow \Phi(x) - \Phi(-x)$$

\rightsquigarrow symetria $\Phi(x) = 1 - \Phi(-x) \quad \hookrightarrow = \underline{\underline{2\Phi(x) - 1}}$

$$P\left(|\sum X_i - mEX_i| \leq 1,645 \cdot \sqrt{m\sigma^2}\right) = 0,9$$

\hookrightarrow roste s m.

$$P\left(|\sum X_i - mEX_i| \leq 0,67 \sqrt{m\sigma^2}\right) = 0,5$$

\hookrightarrow roste male & meze

$$m = 10^4, \quad \sigma = 1$$

$$\rightarrow P\left[\left|\sum_{i=1}^{10^4} X_i - 10^4 EX\right| \leq 67\right] = 0,5$$

ale

$$P\left[\left|\frac{1}{n} \sum X_i - EX\right| \leq 3 \sqrt{\frac{\sigma^2}{n}}\right] = 0,999$$

$$P\left[\left|\bar{X}_{10000} - EX\right| \leq 0,03\right] = 0,999$$

Chernoffovy meze

Def: Bud X náh. veličina. Funkci $\gamma_X(t) = Ee^{tX}$ nazveme momentová momentující funkci X .

Pozn. Pro CNV je $\gamma_X(t) = \sum_{k \in \mathbb{Z}} e^{tk} P[X=k]$

Pro ASV je $\gamma_X(t) = \int_{-\infty}^{\infty} e^{tx} f_X(x) dx$

$\gamma_X(t)$ může být po mnoho t nekonečna

$$\gamma_X(0) = 1$$

~~Pokud $\gamma_X(t)$ existuje konečna na otevřeném ~~intervalu~~ okolí $(-\delta, \delta)$, pak charakt. rozdělení X, Y a platí $\gamma_X(t) = \gamma_Y(t) < \infty \forall t \in (-\delta, \delta) \Rightarrow F_X = F_Y$~~

Věta:

Pokud $\gamma_X(t)$ ex. konečna na otevř. okolí 0, pak charakt. rozdělení X, Y a $\gamma_X(t) = \gamma_Y(t) < \infty \forall t \in (-\delta, \delta) \Rightarrow F_X = F_Y$

Věta: X, Y nezá. n.v.

$$\gamma_{X+Y}(t) = \gamma_X(t) \gamma_Y(t), \text{ speciálně}$$

$$\gamma_{\sum X_i}(t) = \gamma_{X_1}^m(t), \text{ pokud } X_1, \dots, X_m \text{ jsou stejné rozdel.}$$

Dě:

$$\gamma_{X+Y}(t) = Ee^{t(X+Y)} = Ee^{tX} e^{tY} \stackrel{\text{nezá.}}{=} Ee^{tX} Ee^{tY} = \gamma_X(t) \gamma_Y(t)$$

Př:

$$Bi(m, p) = P[X=k] = \binom{m}{k} p^k (1-p)^{m-k}$$

$$\gamma_X(t) = \sum_{k=0}^m e^{tk} \binom{m}{k} p^k (1-p)^{m-k} = \dots = (1-p + e^{tp})^m$$

$$\begin{aligned} X \sim Bi(m_1, p) \\ Y \sim Bi(m_2, p) \end{aligned} \left. \vphantom{\begin{matrix} X \\ Y \end{matrix}} \right\} \text{nezá.} \Rightarrow \gamma_{X+Y}(t) = (1-p + e^{tp})^{m_1} (1-p + e^{tp})^{m_2} = \\ = (1-p + e^{tp})^{m_1+m_2} = \gamma_X(t) \gamma_Y(t)$$

Věta Necht X náh. veličina a $\psi_X(t) < \infty \forall t \in (-t_0, t_0)$
pro $t_0 > 0$. Pak

$$E|X|^r < \infty \forall r \in \mathbb{N} \text{ a platí } EX^r = \psi_X^{(r)}(0)$$

(= r -tá derivace v 0).

Dk:

Za podmínek věty lze zaměnit derivaci a integrál
resp. ~~sumu~~ sumu... $(\int_{-\infty}^{\infty} e^{tx} f(x) dx)_0^{(r)} = \int_{-\infty}^{\infty} (e^{tx})_0^{(r)} f(x) dx =$
 $= \int_{-\infty}^{\infty} x^r f(x) dx = EX^r$; přičemž

$$(e^{tx})_0^{(r)} = x^r e^{tx} \Big|_{t=0} \quad r\text{-tá deriv. podle } t \text{ v } 0.$$

Chernoffovy meze - Věta:

Bud X náh. veličina a $\psi_X(t)$ její mtr. funkce. Pak

$$P(X \geq a) \leq \inf_{t > 0} \frac{\psi_X(t)}{e^{ta}} \quad \text{a} \quad P(X \leq a) \leq \inf_{t < 0} \frac{\psi_X(t)}{e^{ta}}$$

Dk: $\forall t > 0: P(X \geq a) = P(e^{tX} \geq e^{ta}) = P\left(\frac{e^{tX}}{e^{ta}} \geq 1\right) =$

$$= \int_{\{X: \frac{e^{tX}}{e^{ta}} \geq 1\}} f(x) dx \leq \int_{\{X: \frac{e^{tX}}{e^{ta}} \geq 1\}} \frac{e^{tX}}{e^{ta}} f(x) dx \leq \int_{-\infty}^{\infty} e^{tX} f(x) dx \cdot \frac{1}{e^{ta}} =$$

↑
roztoucí v X a a

$$\text{CNV: } \sum_{X: \frac{e^{tX}}{e^{ta}} \geq 1} P(X=X)$$

$$= \frac{\psi_X(t)}{e^{ta}} \leq 1$$

a obdobně

$$\Rightarrow P(X \geq a) \leq \inf_{t > 0} \frac{\psi_X(t)}{e^{ta}} \quad \text{druhý podobně}$$

Vybrané statistické úlohy a jejich řešení pomocí ZVČ a CLV

• Uvažujme X_1, X_2, \dots, X_n náh. velic. se st. rozdeř. (Tzv.

NAHODNÝ VÝBĚR)

$$P(X_i = 1) = p = 1 - P(X_i = 0). \quad \text{kolik je } p?$$

1. bodový odhad

2. intervalový odhad

μ neznáme, jediné, co víme je, že (x_1, \dots, x_n) jsou hodnoty náh. měřen.

B.O. - číselné číslo (přesně možno "blíže" μ)

I.O. - číselný interval, kterým obsahuje neznámé μ s nějakou pravděpodobností (+ co nejmenší).

Bodový odhad - metoda momentů

$$EX = \mu \text{ (neznáme)}$$

$$P(|\bar{X}_n - EX| \geq \varepsilon) \rightarrow 0 \quad \forall \varepsilon > 0 \quad \text{Nezávisle na } EX, \text{ čili } \forall \mu.$$

↑ Měřový průměr

$$|\bar{X}_n - \mu| \xrightarrow{P} 0 \quad \dots \text{ konzistence odhadu}$$

X_1, \dots, X_n - rozdílné s hustotou $\lambda e^{-\lambda x}, x > 0, \lambda > 0$ param.

λ neznáme

$$EX = 1/\lambda \quad (\text{1x per factes})$$

$$P\left[|\bar{X}_n - \frac{1}{\lambda}| \geq \varepsilon\right] \xrightarrow{n \rightarrow \infty} 0$$

$\varphi(z) = \frac{1}{z}$ spojité funkce na $z > 0$.

$$P\left[|\varphi(\bar{X}_n) - \varphi(1/\lambda)| \geq \varepsilon\right] \rightarrow 0 \quad \xrightarrow{n \rightarrow \infty} P\left[\left|\frac{1}{\bar{X}_n} - \lambda\right| \geq \varepsilon\right] \xrightarrow{n \rightarrow \infty} 0$$

... MOMENTOVÁ METODA... $EX = h(\theta)$ h spojité (postí)

• odhadneme EX pomocí \bar{X}_n (pomocí ZVC)

• položíme $\bar{X}_n = h(\hat{\theta})$, kde $\hat{\theta}$ značí bodový odhad

• odtud $\hat{\theta} = \varphi(\bar{X}_n)$

$$\theta \in \mathbb{R}^k \quad EX = h_1(\theta), \dots, EX^k = h_k(\theta)$$

toto vrátíme z modelu. Požad. $E|X|^k < \infty$, pak platí

$$\frac{1}{n} \sum_{i=1}^n X_i^r \xrightarrow{P} EX^r \quad r=1,2,\dots,k$$

$$\bar{X}_n^1 = h_1(\hat{\theta})$$

$$\vdots$$

$$\bar{X}_n^k = h_k(\hat{\theta})$$

$$\rightsquigarrow \hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_k)$$

Nestrannost odhadu

$\hat{\theta}$ je nestranným odhadem θ , pokud $E_{\theta} \hat{\theta} = \theta \quad \forall \theta$

\hookrightarrow str. hodnota, je-li parametr operandu θ

např. u odhadu

$$\hat{p} = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \quad P[X_i=1] = p = 1 - P[X_i=0]$$

platí

$$E_p X_1 = 1 \cdot p + 0 \cdot (1-p) = p$$

$$E_p \hat{p} = E_p \left(\frac{1}{n} \sum X_i \right) = \frac{1}{n} \sum \overbrace{E_p X_i}^p = p \Rightarrow \text{je Nest. odh.}$$

\hat{p} je nestranný odhad pravděp.

úspěchu v alternativním

rozdělení i konzistentní

$$\boxed{\begin{aligned} E(\bar{X}_n) &= EX_1 \\ \text{var } \bar{X}_n &= \frac{1}{n} \text{var } X_1 \end{aligned}}$$

Bodové a intervalové odhady:

Def: Parametrickou třídou rozdělení rozumíme množinu $\mathcal{P} = \{P_\theta; \theta \in \Theta\}$, kde P_θ jsou rozdělení na prostoru $\mathcal{R}(\mathbb{R}^d)$, Θ je známý prostor parametrů (Θ je typicky podmnožina \mathbb{R}^k) a platí $\theta_1 \neq \theta_2 \Rightarrow P_{\theta_1} \neq P_{\theta_2}$ (identifikovatelnost).

Třída BINOMICKÁ

- lze pro ~~řadu~~ pevně N (# pokusů) jako jednofametrickou s parametrem $p \in (0,1) = \Theta$.

Třída GAUSSOVA

- \forall rozdělení typu $N(\mu, \sigma^2)$; $\Theta = \mathbb{R} \times \mathbb{R}^k$
(s hustotou $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$)

Def: Náhodným výběrem (o rozsahu n) s rozdělením P_θ rozumíme soubor nezávislých a stejně rozdělených náh. veličin X_1, \dots, X_n , kde X_i má rozd. P_θ ti.

Pozn. X_1, \dots, X_n náhodný výběr (náh. veličiny)

x_1, \dots, x_n realizace náh. výběru (naměřené hodnoty)

Def: Bodový odhad je funkce $g: \mathbb{R}^n \rightarrow \Theta$

$$g(x_1, \dots, x_n) = \hat{\theta}_n \quad (\text{strážka značí odhad, index rozsah výběru})$$

! Předpis funkce nesmí záviset na θ (což je nepochopitelná hodnota)

$g(x_1, \dots, x_n)$ je náhodná veličina s hodnotami v Θ

$g(x_1, \dots, x_n)$ hodnota odhadu získaná z realizace náh. výběru není náhodná (číslo).

Def Odhad $\hat{\theta}_n$ je **KONZISTENTNÍM** odhadem θ ,
 pokud $\hat{\theta}_n \xrightarrow{P} \theta \quad \forall \theta \in \Theta$
 T.j. po $\forall \theta$ má platit $g(X_1, \dots, X_n) \xrightarrow{P} \theta$, je-li (X_1, \dots, X_n)
 náh. výběr z rozdělení P_θ .

Jak takový odhad najít? \rightsquigarrow Nejučinnější je metoda momentů:

	Teoret. moment	Výběrový moment
	$EX = \mu_1(\theta)$	$\frac{1}{n} \sum X_i = \bar{X}_n$
$\theta \in \Theta = \mathbb{R}^k$	$EX^2 = \mu_2(\theta)$	$\frac{1}{n} \sum X_i^2 = \overline{X_n^2}$
	⋮	⋮
	$EX^k = \mu_k(\theta)$	$\frac{1}{n} \sum X_i^k = \overline{X_n^k}$

Př: $N(\mu, \sigma^2)$
 $EX = \mu$
 $EX^2 = \mu^2 + \sigma^2$

$\frac{1}{n} \sum X_i = \hat{\mu}_n$
 $\frac{1}{n} \sum X_i^2 = \hat{\mu}_n^2 + \hat{\sigma}_n^2 = \hat{\sigma}_n^2 + \left(\frac{1}{n} \sum X_i\right)^2$

Jde o konzistentní odhad? \rightsquigarrow Ano, což plyne ze ZVC
 $\frac{1}{n} \sum Y_i \xrightarrow{P} EY$, pokud $E|Y| < \infty$

Př posunutá expon. rozdělení
 hustota $f(x) = e^{-\lambda(x-a)}$, $x > a$, $\lambda > 0$, $a \dots$ posunutí.
 $EX = \frac{1}{\lambda} + a$
 $EX^2 = \frac{1}{\lambda^2} + \left(\frac{1}{\lambda} + a\right)^2 = \frac{2}{\lambda^2} + \frac{2a}{\lambda} + a^2$

Zde není ~~možné~~ vhodné odhadovat „a“ pomocí metody momentů, zkombinujeme odhad „a“ pomocí minima a momentovou metodu po λ .

Tedy $X_1 > a, X_2 > a, \dots, X_n > a$, nabízí se vzít
 $\hat{a}_n = \min(X_1, \dots, X_n) = X_{1:n} = X_{(1)}$

Spočítat rozdělení minima není tak těžké:

$$P[X_{(1)} \leq x] = 1 - P[X_{(1)} > x] = 1 - P\left[\bigcap_{i=1}^n (X_i > x)\right] =$$

$$= 1 - \prod_{i=1}^n P[X_i > x] = 1 - (1 - F(x))^n \text{ a platí } \hat{a}_n \rightarrow a$$

Hledání „nejlepšího“ odhadu pomocí ztrátové funkce:

ztrátová funkce $L(\hat{\theta}_n, \theta) \geq 0$, např. $(\hat{\theta}_n - \theta)^2$ a chceme, aby odhad minimalizoval $EL(\hat{\theta}_n, \theta)$, např. $E(\hat{\theta}_n - \theta)^2 \forall \theta$.
~~to~~ ! to ale nejde obecně, pouze s omezením na další vlastnosti $\hat{\theta}_n$ (např. ~~ne~~ nestrannost).

Def Odhad je **NESTRANNÝ**, pokud $E\hat{\theta}_n = \theta \forall \theta$

(t.j. pokud X_1, \dots, X_n je náh. výběr z P_θ , pak $Eg(X_1, \dots, X_n) = \theta$).
 Jde tedy o odhad s nejmenším rozptylem.

Intervalový odhad:

• Bud' $L \in (0, 1)$ zvolena pravděpodobnost omylu. Intervalový odhadem parametrem θ se spolehlivostí $\approx 1 - L$ rozumíme interval

$(g_L(X_1, \dots, X_n), g_U(X_1, \dots, X_n))$ takový, že

$$P_\theta(g_L(X_1, \dots, X_n) \leq \theta \leq g_U(X_1, \dots, X_n)) \geq 1 - L$$

... cílem je najít g_L a g_U tak, aby interval byl co největší!
 g_L a g_U nemusí záviset na θ , jde o náhodné veličiny - funkce náhodného výběru.

249

Jak zkonstruovat intervalový odhad?
 \rightarrow najdeme funkci $H(X_1, \dots, X_n, \theta)$ tak, aby rozdělení
 H bylo známé (Δ) a nezáviselo na θ
 • pak existují c_L, c_U takové, že

$$P(c_L \leq H(X_1, \dots, X_n, \theta) \leq c_U) = 1 - \alpha$$

$$\downarrow$$

$$P(g_L(X_1, \dots, X_n) \leq \theta \leq g_U(X_1, \dots, X_n)) \geq 1 - \alpha$$

* co kdybychom přidali ASYMPTOTICKÉ?

a na místo (Δ) normální

(t.j. najdeme funkci $H(X_1, \dots, X_n, \theta)$ tak, aby asymptotické rozdělení H bylo známé - normální a nezáviselo na θ)

\rightarrow to nás naučí & použít CLV

$$\frac{\frac{1}{n} \sum_{i=1}^n X_i - EX}{\sqrt{\text{var } X}} \cdot \sqrt{n} \xrightarrow{P} N(0, 1)$$

\hookrightarrow nezávisí na θ .

Intervaldový odhad založený na CLV

- X_1, \dots, X_n je malý výběr z rozdělení s distribuční funkcí F_θ , $\theta \in \Theta$ je neznámý parametr.
- Hledáme dvojici funkcí $g_D(X_1, \dots, X_n)$ a $g_H(X_1, \dots, X_n)$ tak, aby pro $\forall \theta \in \Theta$ platilo $P_\theta(g_D(X_1, \dots, X_n) \leq \theta \leq g_H(X_1, \dots, X_n)) \geq 1 - \alpha$, kde $\alpha \in (0, 1)$ je obvykle malá (nejčastěji $\alpha = 0,05$).
- Hledáme funkci $H(\theta, X_1, \dots, X_n)$ jejíž rozdělení nezávisí na θ , a které známe $\rightarrow P(c_L \leq H(\theta, X_1, \dots, X_n) \leq c_U) \geq 1 - \alpha$

nezávisí na θ a známe
 \Rightarrow máme najít obě konstanty.

? Kdy to jde snadno?

1.) Je-li $\theta = \gamma(EX)$, kde γ je známé prosté zobrazení \rightarrow
 $EX = \gamma^{-1}(\theta)$ \hookrightarrow monotónní ~~alternat.~~

2.) Platí CLV.

• Za platnosti CLV:

$$\sqrt{n} \cdot \frac{\bar{X}_n - EX}{\sqrt{\sigma^2}} \xrightarrow{D} N(0, 1) \text{ --- známé, nezávislé na } \theta.$$

$$\bar{X}_n = \frac{1}{n} \sum X_i \text{ --- výběrový průměr.}$$

$$\sigma^2 = \text{var } X \text{ --- neznáme } \rightarrow \text{rušivý parametr (nuisance)}$$

$$\Rightarrow \sqrt{n} \frac{\bar{X}_n - \gamma^{-1}(\theta)}{\sqrt{\sigma^2}} \text{ má cca } N(0, 1) \text{ rozdělení}$$

Normální rozdělení $N(0, 1)$ je symetrické kolem 0. Platí

$$P(Z \leq x) = P(Z \geq -x) \text{ pro } Z \sim N(0, 1)$$

označme u_α : hodnota tabová, že $P(Z \leq u_\alpha) = \alpha$

\sim t.j. $u_\alpha = \Phi^{-1}(\alpha)$ pro Φ dist. fce $N(0, 1)$.

\rightarrow KVANTIL.

$$\Rightarrow P\left(\sqrt{m} \frac{\bar{X}_m - \gamma^{-1}(\theta)}{\sqrt{\sigma^2}} \leq u_{\frac{1-\alpha}{2}}\right) = \frac{1}{2}$$

$$\& P\left(\sqrt{m} \frac{\bar{X}_m - \gamma^{-1}(\theta)}{\sqrt{\sigma^2}} \geq u_{1-\frac{1-\alpha}{2}}\right) = \frac{1}{2}$$

$$\Rightarrow P\left(u_{\frac{1-\alpha}{2}} \leq \sqrt{m} \frac{\bar{X}_m - \gamma^{-1}(\theta)}{\sqrt{\sigma^2}} \leq u_{1-\frac{1-\alpha}{2}}\right) = 1-\alpha$$

$$\Rightarrow P\left(\bar{X}_m - u_{1-\frac{1-\alpha}{2}} \cdot \sqrt{\frac{\sigma^2}{m}} \leq \gamma^{-1}(\theta) \leq \bar{X}_m + u_{1-\frac{1-\alpha}{2}} \cdot \sqrt{\frac{\sigma^2}{m}}\right) = 1-\alpha$$

\Rightarrow pro roztomci γ :

$$P\left(\gamma\left(\bar{X}_m - u_{1-\frac{1-\alpha}{2}} \sqrt{\frac{\sigma^2}{m}}\right) \leq \theta \leq \gamma\left(\bar{X}_m + u_{1-\frac{1-\alpha}{2}} \sqrt{\frac{\sigma^2}{m}}\right)\right) = 1-\alpha$$

? co se $\sigma^2 \rightarrow$ odhadneme, ale je třeba i tvrzení navíc:

Věta (Cramérova -) Slutského):

~~Ne~~ Necht U_m je posl. náh. veličin tařová, že $U_m \xrightarrow{D} N(0,1)$

i.) Je-li $Y_m \xrightarrow{P} 1$, pak $U_m \cdot Y_m \xrightarrow{D} N(0,1)$.

ii.) Je-li $Y_m \xrightarrow{P} 0$, pak $U_m + Y_m \xrightarrow{D} N(0,1)$.

Dk: (Plán: Najdeme-li odhad S_m^2 rozptylu σ^2 tařový, že

$$\frac{S_m^2}{\sigma^2} \xrightarrow{P} 1, \text{ pak } \underbrace{\sqrt{m} \frac{\bar{X}_m - EX}{\sqrt{S_m^2}}}_{\downarrow D} = \underbrace{\sqrt{m} \frac{\bar{X}_m - EX}{\sqrt{\sigma^2}}}_{\downarrow D} \cdot \underbrace{\sqrt{\frac{\sigma^2}{S_m^2}}}_{\downarrow P}$$

$N(0,1) \qquad N(0,1) \qquad 1$

$$\Rightarrow \uparrow + \text{Slutského věta: } P\left(\gamma\left(\bar{X}_m - u_{1-\frac{1-\alpha}{2}} \sqrt{\frac{S_m^2}{m}}\right) \leq \theta \leq \gamma\left(\bar{X}_m + u_{1-\frac{1-\alpha}{2}} \sqrt{\frac{S_m^2}{m}}\right)\right) = 1-\alpha$$

Tařovým odhadem je za předpokladu $EX^2 < \infty, \text{ var} X > 0$

$$S_m^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X}_m)^2 \dots \text{VÝBĚROVÝ ROZPTYL}$$

(samotný údaj):

$$P(U_n \leq x) \xrightarrow{n \rightarrow \infty} \Phi(x): \forall x \exists \epsilon > 0 \quad P(|Y_n - 1| > \epsilon) \xrightarrow{n \rightarrow \infty} 0$$

$$? P(U_n \cdot Y_n \leq x) \xrightarrow{n \rightarrow \infty} \Phi(x) \quad \forall x$$

$$P([\underbrace{U_n Y_n \leq x}] \cap [|\underbrace{Y_n - 1| \leq \epsilon}]) + P([\underbrace{U_n Y_n \leq x}] \cap [|\underbrace{Y_n - 1| > \epsilon}])$$



$$P([\underbrace{U_n Y_n \leq x}] \cap [|\underbrace{Y_n - 1| \leq \epsilon}]) \leq P([\underbrace{U_n(1-\epsilon) \leq x}] \cap [|\underbrace{Y_n - 1| \leq \epsilon}])$$

$$\geq P([\underbrace{U_n(1+\epsilon) \leq x}] \cap [|\underbrace{Y_n - 1| \leq \epsilon}])$$

↳ volíme min. a max. Y_n (pro odhad)

$$\rightarrow \text{spolu} \quad P(U_n Y_n \leq x) \leq (1+\delta) P(U_n \leq \frac{x}{1-\epsilon})$$

$$\geq (1-\delta) P(U_n \geq \frac{x}{1+\epsilon})$$

$\forall \delta \exists \epsilon \forall n$ umíme najít takové m_0 i že pro $\forall n \geq m_0$ platí uvedené nerovnosti

$$(1-\delta)(1-\gamma) \Phi\left(\frac{x}{1+\epsilon}\right) \leq P(U_n Y_n \leq x) \leq (1+\delta)(1+\gamma) \Phi\left(\frac{x}{1-\epsilon}\right)$$

Příklad: X_1, \dots, X_n buď výběr z rozdělení

$$\Delta \text{ hustotou } f(x) = \begin{cases} \lambda e^{-\lambda x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

kde $\lambda > 0$ je měrný parametr.

$$EX = \int_0^{\infty} x \lambda e^{-\lambda x} dx = \frac{1}{\lambda} \quad x > 0 \rightarrow \text{platí zvl.}$$

$$EX^2 = \int_0^{\infty} x^2 \lambda e^{-\lambda x} dx = \frac{2}{\lambda^2} \Rightarrow \text{var } X = \frac{1}{\lambda^2} \in (0, \infty)$$

\Rightarrow Platí CLV

$$\bar{X}_n, S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \text{ spočítáme a použijeme}$$

$$\text{CLV: } \lambda = 0,05 \Rightarrow n_{1-\alpha/2} = 1,96$$

$$P\left(-1,96 \leq \sqrt{n} \frac{\bar{X}_n - 1/\lambda}{\sqrt{S_n^2}} \leq 1,96\right) = 0,95$$

$$P\left(\bar{X}_n - 1,96 \sqrt{\frac{S_n^2}{n}} \leq 1/\lambda \leq \bar{X}_n + 1,96 \sqrt{\frac{S_n^2}{n}}\right) = 0,95$$

+ obočia sa rovnajú a ok.

II. možnosť \rightarrow vymäžit var $X = 1/\lambda^2$

$$P\left(-1,96 \leq \frac{\bar{X}_n - 1/\lambda}{1/\lambda} \sqrt{n} \leq 1,96\right) = P\left(-1,96 \leq (\lambda \bar{X}_n - 1) \cdot \sqrt{n} \leq 1,96\right) =$$

$$= P\left(\left(1 - \frac{1,96}{\sqrt{n}}\right) \leq \lambda \bar{X}_n \leq \left(1 + \frac{1,96}{\sqrt{n}}\right)\right) =$$

$$= P\left(\frac{1 - \frac{1,96}{\sqrt{n}}}{\bar{X}_n} \leq \lambda \leq \frac{1 + \frac{1,96}{\sqrt{n}}}{\bar{X}_n}\right) = 0,95$$

\leadsto Bodový odhad metódou momentů $\rightarrow \frac{1}{\hat{\lambda}} = \bar{X}_n \rightarrow \hat{\lambda} = \frac{1}{\bar{X}_n}$

? Jač porovnat střední hodnotu 2 náh. veličin? :

$X \dots$ rozdělenu se str. hodnotou μ_X , rozptylem $\sigma_X^2 \in (0, \infty)$ platí
 $Y \dots$ " " " " " μ_Y , rozptylem $\sigma_Y^2 \in (0, \infty)$ CLV

chceme intervalový odhad pro $\mu_X - \mu_Y$

\Rightarrow Použití: tvrzení $\mu_X - \mu_Y = \Delta$. Požad $\Delta \in$ interval spolehlivosti se yohéhlivosti $1-\alpha$, jač řekneme, že dané tvrzení ZAHŮTAŮME s hladinou statist. významnosti.

mějme X_1, \dots, X_m výběr z rozdělenu F_X + mezávislé
 Y_1, \dots, Y_n " " " " F_Y výběry

Jač, aby m a n byly dostatečné velké ($m \rightarrow \infty, \frac{m}{n} \rightarrow \lambda \in (0, \infty)$)

$$\text{z CLV: } \frac{\bar{X}_m - \mu_x}{\sqrt{\frac{s_x^2}{m}}} \xrightarrow{D} N(0,1) \text{ a } \frac{\bar{Y}_m - \mu_y}{\sqrt{\frac{s_y^2}{m}}} \xrightarrow{D} N(0,1)$$

$$\left. \begin{array}{l} \text{var } \bar{X}_m = \frac{\sigma_x^2}{m} \\ \text{var } \bar{Y}_m = \frac{\sigma_y^2}{m} \end{array} \right\} \text{ z nezávislé vztahy čísla nemali}$$

$$\Rightarrow \text{var}(\bar{X}_m - \bar{Y}_m) = \frac{\sigma_x^2}{m} + \frac{\sigma_y^2}{m} \quad \text{z nezávislosti výběrů}$$

$$\frac{\bar{X}_m - \bar{Y}_m - (\mu_x - \mu_y)}{\sqrt{\frac{s_x^2}{m} + \frac{s_y^2}{m}}} \xrightarrow{D} N(0,1)$$

$$P\left(-u_{1-\alpha/2} \leq \frac{\bar{X}_m - \bar{Y}_m - (\mu_x - \mu_y)}{\sqrt{\frac{s_x^2}{m} + \frac{s_y^2}{m}}} \leq u_{1-\alpha/2}\right) =$$

$$= P\left(\bar{X}_m - \bar{Y}_m - u_{1-\alpha/2} \cdot \sqrt{\frac{s_x^2}{m} + \frac{s_y^2}{m}} \leq \mu_x - \mu_y \leq \bar{X}_m - \bar{Y}_m + u_{1-\alpha/2} \cdot \sqrt{\frac{s_x^2}{m} + \frac{s_y^2}{m}}\right) = 1-\alpha$$

\Rightarrow zamítneme nebo ne.

THE END.