

# Pravděpodobnost a statistika

## 1 Axiomy teorie pravděpodobnosti

V roce 1933 zavedl Andrej N. Kolmogorov.

**Definice** (Pravděpodobnostní prostor). Mějme neprázdnou množinu  $\Omega$  a na ní  $\sigma$ -algebru  $\mathcal{F}$ . Na  $\mathcal{F}$  uvažujme pravděpodobnostní míru  $P$ .

Potom  $(\Omega, \mathcal{F}, P)$  se nazývá *pravděpodobnostní prostor*.

**Definice 1** ( $\sigma$ -algebra). Buď  $\Omega$  neprázdná množina. Systém  $\mathcal{F}$  podmnožin  $\Omega$  se nazývá  $\sigma$ -algebra, pokud

1.  $\Omega \in \mathcal{F}$
2.  $A \in \mathcal{F} \Rightarrow \Omega \setminus A \in \mathcal{F}$  (uzavřenost na doplňku)
3.  $\{A_i\}_{i=1}^{\infty} \subseteq \mathcal{F} \Rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{F}$  (uzavřenost na spočetném sjednocení)

**Příklad.** Ukažme si různé příklady  $\sigma$ -algeber:

- triviální:  $\{\emptyset, \Omega\}$
- největší:  $2^{\Omega}$
- $B \subset \Omega : \{\emptyset, B, B^c, \Omega\}$
- $A, B : \{\emptyset, A, B, A \cup B, A \cap B, A^c, B^c, \dots\}$

**Definice 2** (Pravděpodobnostní míra). Funkce  $P : \mathcal{F} \rightarrow [0, 1]$ , kde prvky  $\mathcal{F}$  jsou podmnožiny  $\Omega$  nazveme *pravděpodobnostní míra*, pokud splňuje následující podmínky:

1.  $P(\Omega) = 1$
2.  $\{A_i\}_{i=1}^{\infty} \subset \mathcal{F}$  a  $A_i \cap A_j = \emptyset \forall i \neq j \Rightarrow P(\bigcup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$  (spočetná aditivita)

**Definice.**  $\omega \in \Omega$  se nazývá *elementární jev*.  $A \in \mathcal{F}$  se nazývá *náhodný jev*.

Elementární jevy většinou nelze pozorovat přímo, je potřeba pozorovat náhodné jevy.

**Příklad.** Mějme hod kostkou. Potom:

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$

$$\omega = 4$$

$$A = \{2, 4, 6\}$$

$P$  každému náhodnému jevu  $A$  jen dá jeho pravděpodobnost.

1. Jestliže  $P(A) = 1$ , potom  $A$  je jev *jistý*.
2. Jestliže  $P(A) = 0$ , potom  $A$  je jev *nemožný*.

**Věta 1.** Buď  $P$  pravděpodobnostní míra na  $\mathcal{F}$ . Pak platí následující:

1.  $P(A^c) = 1 - P(A) \forall A \in \mathcal{F}$
2.  $A, B \in \mathcal{F} : A \subset B$ , pak  $P(A) \leq P(B)$  a  $P(B \setminus A) = P(B) - P(A)$

*Důkaz.* Jednotlivé body:

1.  $P(A \cup A^c) = P(A) + P(A^c)$ . Jelikož  $A \cup A^c = \Omega$  a podle vlastností pravděpodobnostní míry  $P(\Omega) = 1$ ,  $P(A) + P(A^c) = 1$ .
2.  $A \subset B \Rightarrow B = A \cup (B \setminus A)$ . To jsou dvě disjunktní množiny. Potom  $P(B) = P(A) + P(B \setminus A) \geq P(A)$ .

□

Veźměme si systém  $\{A_i\}_{i=1}^{\infty} \subset \mathcal{F}$ . Budeme předpokládat  $A_i \subset A_{i+1}$ . Potom budeme myslet  $A_i \nearrow A$ , kde  $A = \bigcup_{i=1}^{\infty} A_i$ , tedy že systém konverguje k  $A$ .

Analogicky systém, kde  $A_i \supset A_{i+1}$  potom  $A_i \searrow A$ , kde  $A = \bigcap_{i=1}^{\infty} A_i$

**Věta 2** (Spojitost pravděpodobnostní míry). *Nechť máme  $\{A_i\}_{i=1}^{\infty} \subset \mathcal{F}$  takovou, že  $A_i \searrow \emptyset$ . Pak*

$$\lim_{i \rightarrow \infty} P(A_i) = 0.$$

*Důkaz.* Víme, že  $P(\bigcap_{i=1}^{\infty} A_i) = P(\emptyset) = 0$ . To je ekvivalentní s  $1 - P((\bigcap_{i=1}^{\infty} A_i)^c) = 1 - P(\bigcup_{i=1}^{\infty} A_i^c) = 1$ .

Dále víme, že  $A_i \supseteq A_{i+1}$  a díky tomu  $A_i^c \subseteq A_{i+1}^c$ , tedy  $A_i^c \nearrow \Omega$ .

Nadefinujeme si posloupnost  $B_1 = A_1^c, B_{i+1} = A_{i+1}^c \setminus A_i^c$ .

Potom  $B_i$  jsou disjunktní,  $\bigcup_{i=1}^{\infty} B_i = \Omega$  a  $P(\bigcup_{i=1}^{\infty} B_i) = P(\omega) = 1$  a z toho  $\sum_{i=1}^{\infty} P(B_i) = 1$ .

Ten si rozložíme na dva součty  $\sum_{i=1}^n P(B_i)_{\rightarrow 1} + \sum_{i=n+1}^{\infty} P(B_i)_{\rightarrow 0} = 1$  pro  $n \rightarrow \infty$ .

Potom  $P(\bigcup_{i=1}^n B_i) = P(\bigcup_{i=1}^n A_i^c) = 1 - P(\bigcap_{i=1}^n A_i)$ . Z konvergence se toto rovná  $1 - P(A_n)$ . Víme, že tento výsledek konverguje k 1, tedy proto  $P(A_n) \rightarrow 0$ . □

**Definice 3** (Klasický pravděpodobnostní prostor). Buď  $\Omega$  neprázdná konečná množina,  $\mathcal{F} = 2^{\Omega}$ . Definujeme  $P(A) = \frac{|A|}{|\Omega|} \forall A \subset \Omega$ . Potom  $(\Omega, \mathcal{F}, P)$  nazýváme *klasický pravděpodobnostní prostor*.

**Definice 4** (Diskrétní pravděpodobnostní prostor). Buď  $\Omega$  neprázdná konečná nebo spočetná množina,  $\mathcal{F} = 2^{\Omega}$ . Definujeme  $p: \omega \rightarrow \mathbb{R}$  taková, že  $p(\omega) \in [0, 1] \forall \omega \in \Omega$  a  $\sum_{\omega \in \Omega} p(\omega) = 1$ . Dále definujeme  $P(a) = \sum_{\omega \in a} p(\omega)$ . Potom  $(\Omega, \mathcal{F}, P)$  nazýváme *diskrétní pravděpodobnostní prostor*.

Jev  $A$  nastane s  $P(A)$  nebo nenastane s  $P(A^c)$ , jev  $B$  nastal. Pomůže nám tato znalost zpřesnit znalost o jevu  $A$ ?

- Jestliže  $B \supset A$ , potom jev  $A$  nastane vždy.
- Jestliže  $B \cap A = \emptyset$ , jev  $A$  nenastane.
- Jinak se to může chovat všelijak:

**Definice 5** (Podmíněná pravděpodobnost). Mějme jevy  $A, B \in \mathcal{F}, P(B) > 0$ . Definujeme podmíněnou pravděpodobnost jevu  $A$  při  $B$  jako  $P(A|B) = \frac{P(A \cap B)}{P(B)}$ .

Podmíněná pravděpodobnost splňuje vlastnosti pravděpodobnosti míry.

Pozor,  $P(A|B \cup C) \neq P(A|B) + P(A|C)$ !

**Definice 6** (Nezávislost). Jevy  $A, B \in \mathcal{F}$  jsou *nezávislé*, pokud  $P(A \cap B) = P(A) \cdot P(B)$ .

Když jevy  $A, B$  jsou nezávislé, potom  $P(A|B) = \frac{P(A)P(B)}{P(B)} = P(A)$ . Tato vlastnost nezávislosti už nemusí platit pro tři jevy.

**Definice 7** (Vzájemná nezávislost). Buďte  $A_i, i \in I$  náhodné jevy,  $I$  je libovolná indexová množina.  $A_i$  jsou *uzájemně nezávislé*, pokud  $\forall n \in \mathbb{N} \forall i_1, \dots, i_n \subset I$  platí

$$P\left(\bigcap_{j=1}^n A_{i_j}\right) = \prod_{j=1}^n P(A_{i_j})$$

**Věta 3** (O postupném podmiňování). Mějme  $A_1, \dots, A_n$  náhodné jevy (prvky  $\mathcal{F}$ ) takové, že  $P(\bigcap_{i=1}^n A_i) > 0$ . Potom

$$P\left(\bigcap_{i=1}^n A_i\right) = P(A_1 | \bigcap_{i=2}^n A_i) \cdot P(A_2 | \bigcap_{i=3}^n A_i) \cdots P(A_{n-1} | A_n) \cdot P(A_n).$$

*Důkaz.* Matematickou indukcí.

První krok pro  $n = 2$ :  $P(A_1 \cap A_2) = P(A_1 | A_2) \cdot P(A_2)$ .

Nyní pro  $n - 1 \rightarrow n$ :  $P(\bigcap_{i=1}^n A_i) = P((\bigcap_{i=1}^{n-1} A_i) \cap A_n) = P(A_n | \bigcap_{i=1}^{n-1} A_i) \cdot P(\bigcap_{i=1}^{n-1} A_i)$ . □

**Věta 4** (Inkluze a exkluze). Mějme  $A_1, \dots, A_n$  náhodné jevy. Pak

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i \cap A_j) + \sum_{1 \leq i < j < k \leq n} P(A_i \cap A_j \cap A_k) - \cdots + (-1)^{n-1} P\left(\bigcap_{i=1}^n A_i\right)$$

*Důkaz.* Matematickou indukcí.

První krok pro  $n = 2$ :  $A = (A \setminus B) \cup (A \cap B)$ ,  $B = (B \setminus A) \cup (A \cap B)$ .

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

Nyní pro  $n - 1 \rightarrow n$ :  $P(\bigcup_{i=1}^n A_i) = P((\bigcup_{i=1}^{n-1} A_i) \cup A_n) = P(\bigcup_{i=1}^{n-1} A_i) + P(A_n) - P(\bigcup_{i=1}^{n-1} (A_i \cap A_n)) =$   
 $= \sum_{i=1}^{n-1} P(A_i) - \sum_{1 \leq i < j \leq n-1} P(A_i \cap A_j) + \dots + (-1)^{n-2} P(\bigcap_{i=1}^{n-1} A_i) + P(A_n) -$   
 $- \sum_{1 \leq i < j \leq n-1} P(A_i \cap A_n) + \dots + (-1)^{n-2} P(\bigcap_{i=1}^n A_i).$

Nyní dáme dohromady a dostaneme  $\sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i \cap A_j) + \dots + (-1)^{n-1} P(\bigcap_{i=1}^n A_i)$ .  $\square$

Z vlastností množin víme, že  $(\bigcup_{i=1}^n A_i)^C = \bigcap_{i=1}^n A_i^C$  a z toho  $P(\bigcup_{i=1}^n A_i) = 1 - P(\bigcap_{i=1}^n A_i^C)$ .

**Definice 8** (Disjunktní rozklad). Spočetný systém náhodných jevů  $\{B_i\}_{i=1}^{\infty} \subset \mathcal{F}$  nazveme *disjunktním rozkladem*  $\Omega$ , pokud:

1.  $B_i \cap B_j = \emptyset \forall i \neq j$
2.  $\bigcup_i B_i = \Omega$  (stačilo by  $P(\bigcup_i B_i) = 1$ ).
3.  $P(B_i) > 0 \forall i$

**Věta 5** (O úplné pravděpodobnosti). *Mějme  $A$  náhodný jev a  $\{B_i\}_i$  disjunktní rozklad. Pak*

$$P(A) = \sum_i P(A|B_i) \cdot P(B_i)$$

*Důkaz.* Víme, že  $\{A \cap B_i\}$  jsou po dvou disjunktní množiny. Potom  $\bigcup_i A \cap B_i = A \cap \bigcup_i B_i = A \cap \Omega = A$ .

Potom  $P(A) = P(\bigcup_i A \cap B_i) = \sum_i P(A \cap B_i) = \sum_i P(A|B_i) \cdot P(B_i)$ .  $\square$

**Věta 6** (Bayesova). *Mějme  $A$  náhodný jev a  $\{B_i\}_i$  disjunktní rozklad  $\Omega$  a  $P(A) > 0$ . Potom*

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

*Důkaz.* Víme, že  $P(B_i|A) = \frac{P(B_i \cap A)}{P(A)} = \frac{P(A|B_i) \cdot P(B_i)}{\sum_j P(A|B_j) \cdot P(B_j)}$  využitím věty o úplné pravděpodobnosti.  $\square$

Názvosloví...  $P(B_i)$  je apriorní pravděpodobnost,  $P(B_i|A)$  je aposteriorní pravděpodobnost.

**Příklad.** Máme tři zásuvky a 6 mincí, ze kterých jsou 3 zlaté a 3 stříbrné. Do zásuvek náhodně vložíme dvojice ZS, ZZ a SS. Ze zásuvky 2 náhodně vybereme minci náhodně a zjistíme, že je zlatá. Jaká je pravděpodobnost, že i druhá z mincí je zlatá?

Označme si  $B_i$  jako ZZ v zásuvce  $i$ . Toto je disjunktní rozklad. Je  $A$ , náhodný výběr mince ze zásuvky 2, nastal. Potom  $P(A|B_1) = \frac{1}{4}$ ,  $P(A|B_2) = 1$ ,  $P(A|B_3) = \frac{1}{4}$ .

Spočítejme tedy  $P(B_2|A) = \frac{P(A|B_2) \cdot P(B_2)}{\sum_{i=1}^3 P(A|B_i) \cdot P(B_i)} = \frac{1}{\frac{1}{4} + 1 + \frac{1}{4}} = \frac{2}{3}$ !

**Věta 7** (Bonferroniho nerovnost). *Mějme  $A_1, \dots, A_n$  náhodné jevy. Pak*

$$P(\bigcap_{i=1}^n A_i) \geq 1 - \sum_{i=1}^n (1 - P(A_i))$$

*Důkaz.*  $P(\bigcap_{i=1}^n A_i) = 1 - P((\bigcap_{i=1}^n A_i)^C) = 1 - P(\bigcup_{i=1}^n A_i^C) \geq 1 - \sum_{i=1}^n P(A_i^C) = 1 - \sum_{i=1}^n (1 - P(A_i))$ .  $\square$

## 2 Náhodné veličiny a jejich rozdělení

**Definice 9.** Mějme  $(\Omega, \mathcal{F}, P)$  pravděpodobnostní prostor. Zobrazení  $X : \Omega \rightarrow \mathbb{R}$  takové, že  $X^{-1}(-\infty, a] = \{\omega, X(\omega) \leq a\} \in \mathcal{F} \forall a \in \mathbb{R}$  se nazývá *Náhodná veličina*.

**Dohoda o značení.**  $[X \leq a]$  se bude myslet jako  $\{\omega, X(\omega) \leq a\}$ .

**Definice 10** (Rozdělení náhodné veličiny). Buď  $X : \Omega \rightarrow \mathbb{R}$  náhodná veličina. Pravděpodobnostní míra  $P_X$  definovaná na  $\mathbb{R}$  předpisem  $P_X(-\infty, a] = P[X \leq a]$  se nazývá *rozdělení náhodné veličiny*  $X$ .

**Definice.** Označme  $\mathcal{B}$  nejmenší  $\sigma$ -algebru na  $\mathbb{R}$  obsahující všechny intervaly  $(-\infty, a]$ . Nazýváme ji *Borelova (nebo borelovská)*.  $\mathcal{B}$  obsahuje všechny otevřené i uzavřené množiny.

U této množiny poté platí  $\forall B \in \mathcal{B} : X^{-1}(B) \in \mathcal{F}, P_x(B) = P[X \in B]$ .

Náhodná veličina  $X$  nám tedy zobrazuje  $(\Omega, \mathcal{F}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ .

Nabývá-li  $X$  jen spočetně mnoha hodnot ( $X(\omega) \in \mathbb{S} \forall \omega$ ,  $\mathbb{S}$  je spočetná podmnožina  $\mathbb{R}$ ), potom  $X$  splňuje podmínky z definice 9 a  $X$  nazveme *diskrétní* náhodnou veličinou a typicky lze volit  $\mathbb{S} = \mathbb{N}$ .

Rozdělení diskrétní náhodné veličiny  $X$  je plně charakterizováno souborem čísel  $\{p_i\}_{i=1}^{\infty}$ ,  $p_i \geq 0$ ,  $\sum_i p_i = 1$  a  $P_X(A) = \sum_{i \in A} p_i$ .

**Příklad.** Rozdělení diskrétní náhodné veličiny můžou být:

1. Alternativní (Bernoulliho).  $X$  nabývá  $\{0, 1\}$ ,  $P[X = 1] = P_x(\{1\}) = p \in (0, 1)$  a  $P[X = 0] = 1 - p$
2. Binomické. Rozdělení počtu úspěchů do  $n$  nezávislých pokusů.  $P[X = k] = \binom{n}{k} p^k (1 - p)^{n-k}$
3. Geometrické. Počet neúspěchů před prvním úspěchem v nezávislých pokusech.  $P[X = k] = p(1 - p)^k$

Pro jaké množiny  $A \subset \mathbb{R}$  umíme najít  $P_X$ ?

1.  $(-\infty, a]$
2.  $(a, b]$ ,  $a < b = (-\infty, b] \setminus (-\infty, a]$
3.  $(a, b) = \bigcup_{n=1}^{\infty} (a, b - \frac{1}{n}]$
4. Všechny otevřené množiny
5.  $A \in \mathcal{B} \Rightarrow X^{-1} \in \mathcal{F}$  pro všechny  $A \in \mathcal{B}$ ,  $X$  je *Borelovsky měřitelná*

**Definice 11** (Náhodné jevy generované  $X$ ). Mějme  $X$  náhodnou veličinu, označme množinu  $\mathcal{F}_X$  takovou, že  $\mathcal{F}_X = \{B : B = X^{-1}(A) \text{ pro nějakou } A \in \mathcal{B}\}$ .

$\mathcal{F}_X$  je také  $\sigma$ -algebra náhodných jevů generovaných v  $X$ .

$\mathcal{F}_X$  je  $\sigma$ -algebra a  $\mathcal{F}_X \subset \mathcal{F}$ . Potom  $P_X(A) = P[X \in A] = P(X^{-1}(A))_{\in \mathcal{F}_X}$ . Levá strana je míra na  $(\mathbb{R}, \mathcal{B})$ , pravá strana je míra na  $(\Omega, \mathcal{F})$ .

**Příklad.** Mějme  $\Omega = \{1, 2, 3, 4, 5, 6\}^2$ . Dále  $\mathcal{F} = 2^\Omega$  a  $P(\{\omega\}) = \frac{1}{36}$ .

Nadefinujeme si  $X : (\omega_1, \omega_2) \rightarrow \omega_1$ . Potom  $x \in \{1, 2, 3, 4, 5, 6\}$ .

Podívejme se na  $X^{-1}(1) = \{(1, 1), (1, 2), \dots, (1, 6)\}$ . Podobně  $X^{-1}(2) = \{(2, 1), (2, 2), \dots, (2, 6)\}$ . Z toho je vidět, že  $X^{-1}$  jsou navzájem disjunktní. A proto  $\mathcal{F}_X \subsetneq \mathcal{F}$  a  $P_X(1) = \frac{1}{6}$ .

Nyní si nadefinujeme  $Y : (\omega_1, \omega_2) \rightarrow \omega_1 + \omega_2$ . Potom  $Y^{-1}(1) = \emptyset$ , dále  $Y^{-1}(2) = \{(1, 1)\}$  a tak dále.

Tyto náhodné veličiny jsou různé a  $\mathcal{F}_X \neq \mathcal{F}_Y$ . Na jednom pravděpodobnostním prostoru tedy můžeme definovat více různých modelů.

**Definice 12** (Distribuční funkce a hustota). Mějme náhodnou veličinu  $X$  a  $P_X$  její rozdělení. Funkce  $F_X : \mathbb{R} \rightarrow (0, 1)$  definovaná jako  $F_X(x) = P_X[-\infty, x] = P[X \leq x]$  se nazývá *distribuční funkce* náhodné veličiny  $X$  a plně popisuje  $P_X$ .

V angličtině cumulative distribution function C.D.F.

Je-li  $X$  diskrétní náhodná veličina (s hodnotami v  $\mathbb{N}_0$ ), potom funkci  $p_X(k)$  takovou, že  $p_X(k) = P[X = k]$  nazveme *hustotou* náhodné veličiny  $X$  vůči aritmetické míře.

V angličtině probability density function P.D.F.

**Příklad.** Mějme alternativní rozdělení. Potom  $P[X = 1] = p = 1 - P[X = 0]$ . Potom hustota má tvar  $p_X(0) = 1 - p$ ,  $p_X(1) = p$ . Distribuční funkce má tvar

$$F_X(x) = \begin{cases} 0 & x \in (-\infty, 0) \\ 1 - p & x \in [0, 1) \\ 1 & x \in [1, \infty) \end{cases}$$

Obecně má  $F_X(a)$  pro diskrétní náhodnou veličinu  $X$  tvar  $\sum_{k=0}^{\lfloor a \rfloor} p_X(k)$  pro  $a \geq 0$ ,  $p_X(k)$  je  $F_X(k) - F_X(k-1)$  pro  $k \in \mathbb{N}_0$ .

**Věta 8** (Vlastnosti distribuční funkce). Mějme náhodnou veličinu  $X$  a její distribuční funkci  $F_X$ . Pak

1.  $\lim_{x \rightarrow -\infty} F_X(x) = 0$
2.  $\lim_{x \rightarrow \infty} F_X(x) = 1$
3.  $F_X$  je neklesající a zprava spojitá

*Důkaz.* Nejprve ukážeme, že  $F_X$  je neklesající. Z definice  $F_X(x) = P[X \leq x] \leq P[X \leq x] + P[x < X \leq y]$ . Tyto dva jevy jsou disjunktní. Proto se předchozí výraz rovná  $P([X \leq x] \cup [x < X \leq y]) = P[X \leq y] = F_X(y)$ . Podobně to platí pro  $F_X(x) = P_X(-\infty, x] \leq P_X(-\infty, x) + P_X(x, y] = P_X(-\infty, y) = F_X(y)$ .

Nyní ukážeme 1. Z definice distribuční funkce  $\lim_{x \rightarrow -\infty} F_X(x) = \lim_{x \rightarrow -\infty} P_X(-\infty, x]$ . Z monotonie můžeme tento výraz přepsat jako  $\lim_{n \nearrow \infty} P_X(-\infty, -n] = \lim_{n \nearrow \infty} P[X \leq -n]$ ; nazvěme  $[X \leq -n] = A_n$ .

Je vidět, že  $A_n \supset A_{n+1}$ . Podle věty 2 dostaneme  $\bigcap_{n=1}^{\infty} A_n = \emptyset$ . Platí tedy, že  $\lim_{n \rightarrow \infty} P(A_n) = 0$ .

Nyní 2. Podobně  $\lim_{x \rightarrow +\infty} F_X(x) = \lim_{n \nearrow \infty} F_X(n) = \lim_{n \nearrow \infty} P_X(-\infty, n) = \lim_{n \nearrow \infty} P[X \leq n] = B_n$ .

Vidíme, že  $B_n \subset B_{n+1}$  a  $\bigcup_{n=1}^{\infty} B_n = \Omega$ . Podle věty 2 se limita rovná 1.

Nakonec ukážeme spojitost zprava.  $\lim_{h \rightarrow 0^+} F_X(f+h) = \lim_{n \rightarrow \infty} P_X(-\infty, x] + P_X(x, x + \frac{1}{n}] = F_X(x) + \lim_{n \rightarrow \infty} P_X(x, x + \frac{1}{n}) = F_X(x)$ .  $\square$

**Věta 9.** *Nechť  $F$  splňuje vlastnosti z věty 8. Pak existuje pravděpodobnostní prostor  $(\Omega, \mathcal{F}, P)$  a náhodná veličina  $X$  takové, že  $F$  je distribuční funkcí na veličině  $X$ .*

*Důkaz.* Kanonickou konstrukcí. Volme  $\Omega = \mathbb{R}$ ,  $\mathcal{F} = \mathcal{B}$  a  $P$  jako míru na  $\mathcal{B}$  definovanou předpisem  $P(-\infty, x] = F(x)$ .

Nyní musíme umět zadefinovat  $P(-a, b) = F(b_-) - F(a)$ . Tímto se dostaneme na míru na  $\mathcal{B}$ . Spojitost  $P$  je důsledkem spojitosti zprava  $F$ .

Nyní zvolíme  $X : \Omega \rightarrow \mathbb{R}$  takové, že  $x(\omega) = \omega$ . Potom  $F_X(a) = P[X \leq a] = P(-\infty, a] = F(a)$ .  $\square$

**Definice 13** (Nezávislost náhodných veličin). Mějme  $X_1, X_2, \dots$  náhodné veličiny definované na  $(\Omega, \mathcal{F}, P)$ . Nazveme je *vzájemně nezávislými*, pokud pro každou konečnou  $I \subset \mathbb{N}$  a každé  $\{x_i\}_{i \in I}$  platí  $P(\bigcap_{i \in I} [X_i \leq x_i]) = \prod_{i \in I} P[X_i \leq x_i]$ .

### 3 Střední hodnota a další momenty

Snahou je najít číselné charakteristiky, které vypovídají o chování náhodné veličiny, jelikož samotná náhodná míra nám moc neřekne.

**Definice 14** (Střední hodnota, obecná definice). Buď  $X$  náhodná veličina (definovaná na  $(\Omega, \mathcal{F}, P)$ ). Hodnotu  $EX = \int_{\Omega} X(\omega) dP(\omega)$ , existuje-li výraz napravo, nazveme *střední hodnotou*  $X$ .

**Definice.** Buď  $\mathbb{S}$  nejvýše spočetná množina taková, že  $P[X \in \mathbb{S}] = 1$ . Pokud navíc  $p_X(s) = P[x = s] > 0 \forall s \in \mathbb{S}$ , pak  $\mathbb{S}$  nazveme *nosičem*  $P_X$ .

**Věta 10** (Střední hodnota diskrétní náhodné veličiny). *Buď  $X$  diskrétní náhodná veličina s hodnotami v  $\mathbb{S}$ . Pak*

$$EX = \sum_{s \in \mathbb{S}} sP[X = s] = \sum_{s \in \mathbb{S}} sP_X(\{s\}) = \sum_{s \in \mathbb{S}} sp_X(s) \quad \text{MLPSS}$$

*Důkaz.* Využijeme definici:  $EX = \int_{\Omega} X(\omega) dP(\omega)$ . Množinu  $\Omega$  si rozdělíme na  $\bigcup_{s \in \mathbb{S}} \{\omega : X(\omega) = s\} = A_s$ . Tyto množiny  $A_s$  jsou navzájem disjunktní a je jich spočetně mnoho.

$\int_{\bigcup A_s} X(\omega) dP(\omega) = \sum_{s \in \mathbb{S}} \int_{A_s} X(\omega) dP(\omega) = \sum_{s \in \mathbb{S}} s \int_{A_s} dP(\omega) = \sum_{s \in \mathbb{S}} s \int_{\Omega} \chi_{A_s}(\omega) dP(\omega) = \sum_{s \in \mathbb{S}} sP(A_s) = \sum_{s \in \mathbb{S}} sP[X = s]$ .  $\square$

**Příklad.** Zkusme najít funkci  $p_X(s)$ ,  $s \in \mathbb{Z}$  takovou, že:

1.  $p_X(s) \geq 0$
2.  $\sum_{s \in \mathbb{Z}} p_X(s) = 1$
3.  $\sum_{s > 0} sp_X(s) = \infty$ ,  $\sum_{s < 0} sp_X(s) = -\infty$

Pro tuto funkci neexistuje střední hodnota, jelikož máme nedefinovanou sumu  $(\infty - \infty)$ .

Pokud  $EX$  existuje a je konečná, pak mluvíme o náhodné veličině s konečnou střední hodnotou.

Pokud  $P[X \geq b] = 1$  pro  $b$  konečnou konstantu, pak  $EX$  existuje a je  $> b$  (analogicky pro  $P[X \leq b]$ ).

Pokud  $\exists a, b$  konečné a  $P[a \leq X \leq b] = 1$ , pak  $EX$  existuje konečná a  $a \leq EX \leq b$ .

Můžeme definovat  $E|X| = \int_{\Omega} |X(\omega)| dP(\omega)$ , která existuje vždy. Pokud  $E|X| < \infty$ , pak  $X \in L_1$  a v tom případě existuje  $|EX| < \infty$ .

Střední hodnota charakterizuje polohu  $X$  ( $P_X$ ).

Mějme  $a, b$  reálné a transformaci  $X \rightarrow a + bX$ . Potom  $E(a + bX) = \sum_s (a + bs)p_X(s)$ . Pokud  $|EX| < \infty$ , můžeme toto přepsat jako  $\sum_s ap_X(s) + \sum_s bsp_X(s) = a + bEX$ . Dá se tedy říct, že v tomto případě se  $EX$  chová lineárně.

**Definice 15** (Obecné momenty náhodné veličiny). Buď  $X : \Omega \rightarrow \mathbb{R}$  náhodná veličina a  $g : \mathbb{R} \rightarrow \mathbb{R}$  funkce taková, že  $g(x)$  je náhodná veličina. Pak  $Eg(x) = \int_{\Omega} g(X(\omega)) dP(\omega)$  MLPSS.

Pro diskrétní náhodné veličiny potom  $Eg(x) = \sum_{s \in \mathbb{S}} g(s)P[X = s]$  MLPSS.

**Definice 16.** Buď  $X$  náhodná veličina. Pak

1. pro  $r \in \mathbb{N}$   $EX^r$  je  $r$ -tý moment  $X$ .
2.  $E|X|^r$  je  $r$ -tý absolutní moment  $X$ . Také pro  $E|x|^r < \infty$  máme  $X \in L_r$ .
3. pro  $r \in \mathbb{N}$   $E(X - EX)^r$  je  $r$ -tý centrální moment  $X$ .
4. pro  $r = 2$  máme  $\text{var } x = E(X - EX)^2$  rozptyl (variance)  $X$ .
5.  $\mu_3 = \frac{E(X-EX)^3}{(E(X-EX)^2)^{\frac{3}{2}}}$  je šikmost rozdělení, měří asymetrii.
6. Momentová vytvořující funkce  $\Psi_X(t), t \in \mathbb{R}$  je  $\Psi_X(t) = Ee^{tX}$  MLPSS. Vždy existuje minimálně  $\Psi_X(0) = 1$ .

Poznámky ohledně momentů:

1. Pokud  $r > t \geq 1$  a  $E|X|^r < \infty$ , pak  $E|X|^t < \infty$ .
2. Jak spočítat rozptyl...  $\text{var } X = \sum_{s \in \mathbb{S}} (s - EX)^2 P[X = s]$ .  
Nebo také  $\text{var } X = E(X^2 - 2X \cdot EX + (EX)^2) = EX^2 - E(2X \cdot EX) + E(EX)^2 = EX^2 - (EX)^2$ .  
Nebo také  $\text{var } X = E(X(X - 1)) - EX(EX - 1)$ .
3.  $\text{var } X \geq 0$ . Pokud  $\text{var } X = 0$ , potom  $s = EX, p_X(EX) = 1$ , tedy  $P[X = EX] = 1$ .

**Věta 11** (momenty a  $\psi_X$ ). Buď  $X$  náhodná veličina a  $\psi_X$  její momentová vytvořující funkce. Nechť  $\exists \delta > 0$  takové, že  $\psi_X(t)$  existuje konečně  $\forall |t| < \delta$ . Pak  $\forall r \in \mathbb{N}$   $EX^r = \psi_X^{(r)}(0)$ .

*Důkaz.* V knize Pravděpodobnost a matematická statistika (Dupáč, Hušková). □

**Věta 12** (M.v.f a charakterizace rozdělení). Nechť  $X$  a  $Y$  jsou náhodné veličiny. Nechť  $\exists \delta > 0$  tak, že:

1.  $\psi_X(t), \psi_Y(t)$  existuje konečně  $\forall |t| < \delta$
2.  $\psi_X(t) = \psi_Y(t) \forall |t| < \delta$

Pak  $P_X = P_Y$

**Věta 13** (Jensenova nerovnost). Buď  $X$  náhodná veličina s konečnou střední hodnotou  $EX$ . Buď  $\varphi$  konvexní funkce. Pak  $E\varphi(x) \geq \varphi(EX)$ .

*Důkaz.* Pro  $\varphi \in C^2$ . Potom můžeme použít Taylorův rozvoj. Tedy  $\varphi(X) = \varphi(EX) + \varphi'(EX)(X - EX) + \frac{\varphi''(c)}{2}(X - EX)^2$ . Použijeme střední hodnotu. Dostáváme  $E\varphi(x) = \varphi(EX) + \varphi'(EX) \cdot E(X - EX) + \frac{\varphi''(c)}{2} \cdot \text{var } X \geq \varphi(EX)$ . □

*Důkaz podle Matěje Konečného.* Z definice konvexity máme

$$\varphi(X) \geq \varphi(EX) + \varphi'(EX) \cdot (X - EX),$$

a protože očekávaná hodnota zachovává nerovnosti, tak použitím  $E$  na tuhle nerovnost dostaneme přesně to, co chceme. □

**Věta 14.** *Nebyla přednesena.*

## 4 Náhodné vektory a jejich rozdělení

**Definice 17** (Náhodný vektor). Zobrazení  $\mathbf{X} : \Omega \rightarrow \mathbb{R}^d$ , kde  $(\Omega, \mathcal{F}, P)$  je pravděpodobnostní prostor,  $d \in \mathbb{N}$ ,  $d \geq 2$  takové, že  $\{\omega : \mathbf{X}(\omega) \leq \mathbf{a}\} \in \mathcal{F} \forall \mathbf{a} \in \mathbb{R}^d$  nazveme *náhodný vektor*.

Diskrétní náhodný vektor nabývá nejvýše spočetně mnoha hodnot. Neřekneme-li jinak, budou tyto hodnoty vždy podmnožinou  $\mathbb{N}_0^d$ .

**Definice 18.** Buď  $\mathbf{X}$   $d$ -rozměrný náhodný vektor. Pravděpodobnostní míra  $P_{\mathbf{X}}$  definovaná na  $\mathbb{R}^d$  předpisem  $P_{\mathbf{X}}(\prod_{i=1}^d (-\infty, a_i]) = P[\mathbf{X} \leq \mathbf{a}] \forall \mathbf{a} \in \mathbb{R}^d = P(\bigcap_{i=1}^d [X_i \leq a_i])$  nazveme rozdělení náhodného vektoru.

**Věta 15** (Rozdělení diskrétní náhodné veličiny). Buď  $\mathbf{X}$  diskrétní náhodný vektor a  $P_{\mathbf{X}}$  jeho rozdělení. Pak existuje funkce  $p_{\mathbf{X}} : \mathbb{N}^d \rightarrow [0, 1]$  jednoznačně daná taková, že

$$P_{\mathbf{X}}(\prod_{i=1}^d (-\infty, a_i]) = \sum_{\mathbf{z} \leq \mathbf{a}} p_{\mathbf{X}}(\mathbf{z})$$

**Definice 19** (Distribuční funkce náhodného vektoru). Buď  $\mathbf{X}$  náhodný vektor a  $P_{\mathbf{X}}$  jeho rozdělení.  $F_{\mathbf{X}} : \mathbb{R}^d \rightarrow [0, 1]$  definovaná jako  $F_{\mathbf{X}}(\mathbf{a}) = P[\mathbf{X} \leq \mathbf{a}]$  se nazývá *distribuční funkce* náhodného vektoru  $\mathbf{X}$ .

**Definice 20** (Marginální rozdělení). Buď  $\mathbf{X}$  náhodný vektor a  $P_{\mathbf{X}}$  jeho rozdělení takové, že  $P_{X_i}(-\infty, a] = \lim_{a_j \rightarrow \infty, j \neq i} P_{\mathbf{X}}(X_{j=1}^d(-\infty, a_j])$  se nazývá *marginální rozdělení*  $X_i$  a  $F_{X_i} = \lim_{a_j \rightarrow \infty, j \neq i} F_{\mathbf{X}}(\mathbf{a})$  se nazývá jeho marginální distribuční funkce  $X_i$ .

Vezměme si,  $\mathbf{X} : \Omega \rightarrow \mathbb{R}^d$ . Potom  $\mathbf{X} = (X_1, X_2, \dots, X_d)$ , kde

**Terminologie.**  $P_{\mathbf{X}}, F_{\mathbf{X}}$  jsou sdružené rozdělení, distribuční funkce, zatímco  $P_{X_i}, F_{X_i}$  jsou marginální rozdělení. Nemáme však speciální termín pro  $P_{(X_1, X_2, X_8)}$  subvektor.

**Věta 16** (O Marginálním rozdělení). Máme-li náhodný vektor  $\mathbf{X}$  a jeho rozdělení  $P_{\mathbf{X}}$ , pak marginální rozdělení složek  $X_1, \dots, X_d$  jsou jednoznačně určeny  $P_{\mathbf{X}}$ .

*Naopak ne!*

**Příklad.** Hodíme dvěma kostkami. Jejich výsledky jsou  $A, B$ . Dále mějme  $C = A - 1$  pro  $B$  sudé a  $C = A + 1$  pro  $B$  liché. Zapišme si je do tabulky:

$A \setminus B$	1	2	3	4	5	6		$A \setminus C$	1	2	3	4	5	6	
1	1/36	1/36	1/36	1/36	1/36	1/36	1/6	1	0	1/12	0	0	0	1/12	1/6
2	1/36	1/36	1/36	1/36	1/36	1/36	1/6	2	1/12	0	1/12	0	0	0	1/6
3	1/36	1/36	1/36	1/36	1/36	1/36	1/6	3	0	1/12	0	1/12	0	0	1/6
4	1/36	1/36	1/36	1/36	1/36	1/36	1/6	4	0	0	1/12	0	1/12	0	1/6
5	1/36	1/36	1/36	1/36	1/36	1/36	1/6	5	0	0	0	1/12	0	1/12	1/6
6	1/36	1/36	1/36	1/36	1/36	1/36	1/6	6	1/12	0	0	0	1/12	0	1/6
	1/6	1/6	1/6	1/6	1/6	1/6			1/6	1/6	1/6	1/6	1/6	1/6	

Vidíme, že pro náhodné vektory  $(A, B)$  a  $(A, C)$  jsou jejich marginální rozdělení stejná, ale uvnitř se chovají úplně jinak.

Zavedme si značení:  $\mathbf{a} < \mathbf{b}$  právě, když  $a_i < b_i \forall i = 1, \dots, d$ . Dále necht'  $\Delta_k(\mathbf{a}, \mathbf{b})$  je množina těch  $\mathbf{c}$ , pro které existuje právě  $k$  indexů  $i_1, i_2, \dots, i_k$  takových, že  $c_{i_j} = a_{i_j}$  a pro zbytek indexů je  $c_l = b_l$ .

Tedy například pro  $\mathbf{a} = (a_1, a_2, a_3)$ ,  $\mathbf{b} = (b_1, b_2, b_3)$  je  $\Delta_1(\mathbf{a}, \mathbf{b}) = \{(a_1, b_2, b_3), (b_1, a_2, b_3), (b_1, b_2, a_3)\}$ .

**Věta 17** (Vlastnosti distribuční funkce). Buď  $F_{\mathbf{X}}$  sdružená distribuční funkce náhodného vektoru  $\mathbf{X}$ . Pak:

- $\lim_{a_i \rightarrow -\infty} F_{\mathbf{X}}(\mathbf{a}) = 0$  pro libovolné  $i$ .
- $\lim_{a_i \rightarrow \infty} F_{\mathbf{X}}(\mathbf{a}) = 1$  pro každé  $i$ .
- V každé složce argumentu je  $F_{\mathbf{X}}$  zprava spojitá a neklesající
- $\forall \mathbf{a} < \mathbf{b}$  platí  $\sum_{k=0}^d (-1)^k \sum_{\mathbf{c} \in \Delta_k(\mathbf{a}, \mathbf{b})} F_{\mathbf{X}}(\mathbf{c}) \geq 0$

Podívejme se na čtvrtou podmínku pro  $\mathbf{a} = (a_1, a_2)$ ,  $\mathbf{b} = (b_1, b_2)$ . Pak tato podmínka říká, že pro  $\mathbf{a} < \mathbf{b}$  platí, že  $(b_1, b_2) - ((a_1, b_2) + (b_1, a_2)) + (a_1, a_2) \geq 0$ . Jedná se tedy o výřez na boxu  $(a_1, b_1) \times (a_2, b_2)$ .

**Věta 18** (Charakterizace distribuční funkce). Necht'  $F : \mathbb{R}^d \rightarrow \mathbb{R}$  splňuje vlastnosti z věty 17. Pak existují  $(\Omega, \mathcal{F}, P)$  a  $\mathbf{X} : \Omega \rightarrow \mathbb{R}^d$  takové, že  $F$  je distribuční funkcí  $\mathbf{X}$ .

*Důkaz.* Stejně, jako u věty 9. □

Náhodné veličiny  $X_1, \dots, X_d$  jsou nezávislé, když  $\forall A_1, \dots, A_d \in \mathcal{B}$  platí  $P(\bigcap_{i=1}^d [X_i \in A_i]) = \prod_{i=1}^d P[X_i \in A_i]$ .

**Věta 19** (Charakterizace nezávislosti). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  náhodný vektor a  $F_{\mathbf{X}}$  jeho sdružená distribuční funkce. Pak  $X_1, \dots, X_d$  jsou nezávislé náhodné veličiny, pokud  $\forall a_1, \dots, a_d \in \mathbb{R}$  platí*

$$F_{\mathbf{X}}(a_1, \dots, a_d) = \prod_{i=1}^d F_{X_i}(a_i).$$

Pro diskrétní náhodný vektor je nezávislost  $X_1, \dots, X_d$  ekvivalentní tomu, že  $p_{\mathbf{X}}(a_1, \dots, a_d) = \prod_{i=1}^d p_{X_i}(a_i)$ .

## 5 Náhodné vektory a momenty

**Definice 21** (Střední hodnota náhodného vektoru). *Buď  $\mathbf{X}$  náhodný vektor. Potom definujeme:*

1.  $E\mathbf{X} = (EX_1, \dots, EX_d)$
2. Nechť  $g : \mathbb{R}^d \rightarrow \mathbb{R}$  (taková, že  $g(\mathbf{X})$  je náhodná veličina). Pak definujeme  $Eg(\mathbf{X}) = \int_{\Omega} g(\mathbf{X}(\omega)) dP(\omega)$ , pokud všechny integrály existují.

Je-li  $\mathbf{X}$  diskrétní, pak  $Eg(\mathbf{X}) = \sum_{\mathbf{z} \in \mathbb{N}_0^d} g(\mathbf{z})P[\mathbf{X} = \mathbf{z}]$ , existuje-li řada napravo.

Když si vezmeme funkci  $g_i : \mathbb{R}^d \rightarrow \mathbb{R}$ , která splňuje  $g_i(\mathbf{X}) = X_i$ , potom  $Eg_i(\mathbf{X}) = EX_i$ .

**Věta 20** (Linearita střední hodnoty). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  náhodný vektor a konstanty  $a \in \mathbb{R}, b_1, \dots, b_d \in \mathbb{R}$  a  $E|X_i| < \infty \forall i$ . Pak*

$$E\left(a + \sum_{i=1}^d b_i X_i\right) = a + \sum_{i=1}^d b_i EX_i.$$

*Důkaz.* Jen pro diskrétní náhodný vektor, indukci.

Vezměme si  $(X_1, X_2)$  a  $a, b_1, b_2$ . Potom  $E(a + b_1 X_1 + b_2 X_2) = \sum_{\mathbf{z} \in \mathbb{N}_0^d} (a + b_1 z_1 + b_2 z_2)P[X_1 = z_1, X_2 = z_2] = \sum_{\mathbf{z} \in \mathbb{N}_0^d} aP[X_1 = z_1, X_2 = z_2] + \sum_{\mathbf{z} \in \mathbb{N}_0^d} b_1 z_1 P[X_1 = z_1, X_2 = z_2] + \sum_{\mathbf{z} \in \mathbb{N}_0^d} b_2 z_2 P[X_1 = z_1, X_2 = z_2]$ .

Pro první sumu platí, že  $\sum_{\mathbf{z} \in \mathbb{N}_0^d} aP[X_1 = z_1, X_2 = z_2] = a$ .

Pro druhou sumu dostaneme  $\sum_{\mathbf{z} \in \mathbb{N}_0^d} b_1 z_1 P[X_1 = z_1, X_2 = z_2] = \sum_{z_1=0}^{\infty} \sum_{z_2=0}^{\infty} b_1 z_1 P[X_1 = z_1, X_2 = z_2] = \sum_{z_1=0}^{\infty} b_1 z_1 P[X_1 = z_1, X_2 = z_2]$ . Můžeme použít větu 5, kde  $\bigcup_{z_2=0}^{\infty} [X_2 = z_2] = \Omega$ . Nakonec se suma bude rovnat  $b_1 \sum_{z_1=0}^{\infty} z_1 P[X_1 = z_1] = b_1 EX_1$ . Analogicky pro třetí sumu.

Celá suma se tedy nakonec rovná  $a + b_1 EX_1 + b_2 EX_2$ .

Takto můžeme indukci projít všechny dimenze. □

**Poznámka.** Předpoklad  $\mathbf{X} = (X_1, \dots, X_d)$  je náhodný vektor a zaručuje, že  $X_1, \dots, X_d$  jsou definované na stejném pravděpodobnostním prostoru a mají sdružené rozdělení  $P_{\mathbf{X}} = P_{(X_1, \dots, X_d)}$ .

**Věta 21** (Střední hodnota součinu). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  náhodný vektor,  $E|X_i| < \infty \forall i$ . Jsou-li  $X_1, \dots, X_d$  nezávislé, pak*

$$E \prod_{i=1}^d X_i = \prod_{i=1}^d EX_i.$$

*Důkaz.* Jen pro diskrétní náhodný vektor, indukci. Postup podobný, jako u předchozí věty.

Máme  $(X_1, X_2)$ . Potom  $EX_1 X_2 = \sum_{\mathbf{z} \in \mathbb{N}_0^d} z_1 z_2 P[X_1 = z_1, X_2 = z_2] = \sum_{\mathbf{z} \in \mathbb{N}_0^d} z_1 P[X_1 = z_1, X_2 = z_2] \cdot z_2 P[X_1 = z_1, X_2 = z_2]$ .

Máme tedy součet  $\sum_{z_1=0}^{\infty} \sum_{z_2=0}^{\infty} z_1 P[X_1 = z_1, X_2 = z_2] \cdot z_2 P[X_1 = z_1, X_2 = z_2]$ . Díky nezávislosti se tato suma rovná  $\sum_{z_1=0}^{\infty} z_1 P[X_1 = z_1, X_2 = z_2] \cdot \sum_{z_2=0}^{\infty} z_2 P[X_1 = z_1, X_2 = z_2] = EX_1 \cdot EX_2$ . □

Dříve jsme zjistili, že  $X_1, X_2$  jsou nezávislé právě, když  $F_{(X_1, X_2)}(x_1, x_2) = F_{X_1}(x_1)F_{X_2}(x_2)$ . Nyní díky větě 21 víme, že  $X_1, X_2$  jsou nezávislé  $\Rightarrow EX_1 X_2 = EX_1 EX_2$ . Opačná implikace však obecně neplatí.

Postačí si představit náhodné veličiny  $X = \{-1, 0, 1\}, Y = \{1, 2\}$ , pro které platí:  $EX_1 X_2 = 0, EX_1 = 0$ . Tedy  $EX_1 X_2 = EX_1 EX_2$ . Samotné pravděpodobnosti ale jsou  $P[X = -1] = \frac{1}{3}, P[Y = 1] = \frac{1}{3}$ . Avšak  $P[X = -1, Y = 1] = 0 \neq \frac{1}{9}$ . Nejsou tedy nezávislé.

**Definice 22** (Kovariance náhodných veličin). *Buď  $(X_1, X_2)$  náhodný vektor takový, že  $\text{var } X_1 < \infty, \text{var } X_2 < \infty$ . Definujeme kovarianci  $\text{cov}(X_1, X_2) = E(X_1 - EX_1)(X_2 - EX_2)$ .*



Co tato kovariance znamená?  $X_1 - EX_1, X_2 - EX_2$  je odchylka od střední hodnoty.  $(X_1 - EX_1)(X_2 - EX_2)$  je kladné, když násobíme odchylky stejného znaménka, či záporné, když odchylky mají různé znaménko. Dále tento součin říká, jak jsou obě veličiny daleko.

Co se stane, když si vezmeme  $E(X_1 - EX_1)(X_2 - EX_2)$ ? Pokud je kladná, můžeme očekávat, že obě hodnoty budou růst. Například u vysokého člověka můžeme očekávat, že bude mít i vysokou hmotnost. Když je záporná, je tomu naopak.

Jak se dá kovariance počítat? Můžeme využít přímou definici. Ta však není moc pohodlná.

Podobně jako pro rozptyl můžeme tento vzoreček zjednodušit:  $E((X_1 - EX_1)(X_2 - EX_2)) = E(X_1X_2 - X_1EX_2 - X_2EX_1 + EX_1EX_2)$ .

Díky větě 20 můžeme tento výraz rozepsat jako  $EX_1X_2 - E(X_1EX_2) - E(X_2EX_1) + E(EX_1EX_2) = EX_1X_2 - EX_1EX_2$ .

Důsledkem věty 21 je, že nezávislé  $X_1, X_2$  mají nulovou kovarianci.

Platí, že  $\text{cov}(X_1, X_1) = \text{var } X_1$  a kovariance je symetrická.

**Věta 22** (Rozptyl součtu náhodných veličin). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  náhodný vektor,  $\text{var } x_i < \infty \forall i$ . Pak*

$$\text{var} \left( \sum_{i=1}^d X_i \right) = \sum_{i=1}^d \text{var } X_i + \sum_{1 \leq i \neq j \leq d} \text{cov}(X_i, X_j) = \sum_{i=1}^d \text{var } X_i + 2 \sum_{1 \leq i < j \leq d} \text{cov}(X_i, X_j).$$

*Speciálně, jsou-li  $X_1, \dots, X_d$  nezávislé, pak*

$$\text{var} \left( \sum_{i=1}^d X_i \right) = \sum_{i=1}^d \text{var } X_i.$$

*Důkaz.* Podle definice rozepíšeme a postupnou úpravou:  $\text{var} \left( \sum_{i=1}^d X_i \right) = E \left( \sum_{i=1}^d X_i - E \left( \sum_{i=1}^d X_i \right) \right)^2 = E \left( \sum_{i=1}^d (X_i - EX_i)^2 + 2 \sum_{1 \leq i < j \leq d} (X_i - EX_i)(X_j - EX_j) \right) = \sum_{i=1}^d \text{var } X_i + 2 \sum_{1 \leq i < j \leq d} \text{cov}(X_i, X_j)$ .  $\square$

**Příklad.** Mějme  $X_1, X_2$  nezávislé, kde  $\sigma^2 = \text{var } X_1 = \text{var } X_2$ . Podle věty 22:

1.  $\text{var}(X_1 + X_2) = \text{var } X_1 + \text{var } X_2 = 2\sigma^2$
2.  $\text{var}(X_1 - X_2) = \text{var } X_1 + \text{var } X_2 = 2\sigma^2$
3.  $\text{var}(X_1 + X_1) = \text{var } X_1 + \text{var } X_1 + 2 \text{cov}(X_1, X_1) = 4 \text{var } X_1 = 4\sigma^2$
4.  $\text{var}(X_1 - X_1) = \text{var } X_1 + \text{var } X_1 - 2 \text{cov}(X_1, X_1) = 0$

Již umíme spočítat  $\text{cov}(X_i, X_j)$ . Představme si, že  $Z_i = 1000X_i$  (kg  $\rightarrow$  g). Potom ale získáváme rovnost  $\text{cov}(Z_i, Z_j) = 1000 \text{cov}(X_i, X_j)$ , což je mnohem vyšší číslo.

Chtěli bychom tedy, aby kovariance byla bezrozměrná, tedy chceme  $\varphi(X) : \varphi(aX) = |a|\varphi(X)$ .

Potom  $\frac{\text{cov}(aX, bY)}{\varphi(aX)\varphi(bY)} = \frac{\text{cov}(X, Y)}{\varphi(X)\varphi(Y)}$ .

**Definice.** *Korelací nazveme  $\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var } X \text{var } Y}}$ .*

**Definice 23** (Varianční a korelační matice). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  náhodný vektor,  $\text{var } X_i < \infty \forall i = 1, \dots, d$ . Potom varianční matice je  $\text{Var } \mathbf{X} = \{\text{cov}(X_i, X_j)\}_{i,j}$  a korelační matice je  $\text{Corr } \mathbf{X} = \{\text{corr}(X_i, X_j)\}_{i,j}$ .*

Varianční matice  $\text{Var } \mathbf{X}$  má díky definici na diagonále právě  $\text{var } X_i$ . Podobně korelační matice má na diagonále samé jedničky.

**Značení.**

- $\text{corr}(X, Y) = \rho_{X,Y}$
- $\text{var } X = \sigma_X^2$
- $\text{cov}(X, Y) = \sigma_X \sigma_Y \rho_{X,Y}$
- $EX = \mu_X$

**Věta 23** (Vlastnosti kovariance a korelace). *Budte  $\mathbf{X}$  náhodný vektor s variační maticí  $\text{Var } \mathbf{X}$  (existuje, konečné prvky). Dále mějme  $X, Y$  náhodné veličiny s konečným rozptylem. Potom:*

1.  $-1 \leq \text{corr}(X, Y) \leq 1, \text{corr}(X, X) = 1$
2.  $|\text{corr}(X, Y)| = 1 \Leftrightarrow \exists a \neq 0, b \in \mathbb{R} : X = aY + b$
3.  $\text{cov}(aX + c, bY + d) = ab \text{cov}(X, Y)$
4.  $\text{corr}(aX + c, bY + d) = \text{sgn}(ab) \text{corr}(X, Y)$
5. *jsou-li  $X, Y$  nezávislé,  $\text{cov}(X, Y) = 0$*
6.  $\text{Var } \mathbf{X}, \text{Corr } \mathbf{X}$  *jsou symetrické pozitivně semidefinitní*
7.  $\forall A \in \mathbb{R}^{l \times d}, B \in \mathbb{R}^l, \mathbf{X} \in \mathbb{R}^d : \text{Var}(A\mathbf{X} + B) = A(\text{Var } \mathbf{X})A^T$

*Důkaz.* Jen některé body.

1. Máme vlevo  $E((X - EX)(Y - EY))$ , vpravo  $\sqrt{E(X - EX)^2 E(Y - EY)^2}$ .  
Pro diskrétní náhodné veličiny získáváme vlevo  $\sum_u \sum_v (u - EX)(v - EY)P[X = u, Y = v]$ , vpravo  $(\sum_u \sum_v (u - EX)^2 P[X = u, Y = v] \cdot \sum_u \sum_v (v - EY)^2 P[X = u, Y = v])^{\frac{1}{2}}$ .  
Nyní využijeme Cauchyho-Schwarzovy nerovnosti. Díky ní poté platí, že levá strana  $\leq$  pravá strana.  
Pro integrály existuje zobecnění zvané Hölderova nerovnost  $\rightarrow$  z ní plyne platnost pro všechny náhodné veličiny  $X, Y$  s konečnými rozptyly.
2. Je-li  $X = aY + B$ , pod ze bodu 3 a 4 získáváme, že  $\text{corr}(X, Y) = \text{corr}(aY + B, Y) = \text{sgn}(a) \text{corr}(Y, Y) = \pm 1$ .  
Naopak, je-li  $|\text{corr}(X, Y)| = 1$ , pak C-S nerovnost vychází jako rovnost a to je možné jen, pokud  $X = aY + b$ .
3. Přímou z definice  $E((aX + c - E(aX + c))(bY + d - E(bY + d))) = E((aX + c - aEX)(bY + bEY)) = ab E((X - EX)(Y - EY))$
4. Víme, že  $\text{var}(aX) = a^2 \text{var } X$  a  $\text{var}(bY) = b^2 \text{var } Y$ . Potom  $\frac{ab \text{cov}(X, Y)}{\sqrt{a^2 \text{var } X b^2 \text{var } Y}} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var } X \text{var } Y}}$
6.  $\forall a \in \mathbb{R}^d : a^T \text{Var } \mathbf{X} a \geq 0$ . Po rozepsání  $a^T \text{Var } \mathbf{X} a = \sum_{i=1}^d \sum_{j=1}^d a_i a_j \text{cov}(X_i, X_j) = \sum_{i=1}^d \text{var}(a_i X_i) + 2 \sum_{1 \leq i < j \leq d} \text{cov}(a_i X_i, a_j X_j) = \text{var}(a^T \mathbf{X}) \geq 0$ .  
Podobně  $\text{Corr } \mathbf{X} = B \text{Var } \mathbf{X} B^T$ , kde  $B_{i,i} = (\text{var } X_i)^{-1}$ . Potom  $a^t \text{Corr } \mathbf{X} a = a^T B \text{var } \mathbf{X} B^T a \geq 0$ .
7. Máme  $A\mathbf{X}$ . Víme  $\text{var } a^t X = a^T \text{var } \mathbf{X} a$ . Podobně, jako u předchozího bodu  $\text{cov}(a^T \mathbf{X}, b^T \mathbf{Y}) = a^T \text{Var } \mathbf{X} b$ . □

Korelace tedy měří míru linearitu závislosti  $X$  a  $Y$ .

Důsledkem sedmého bodu je, že  $\text{cov}(\sum_{i=1}^k X_i, \sum_{j=1}^l Y_j) = \sum_{i=1}^k \sum_{j=1}^l \text{cov}(X_i, Y_j)$  a  $\text{cov}(X + Y, Z) = \text{cov}(X, Z) + \text{cov}(Y, Z)$ . Tedy kovariance je bilineární forma.

Řekněme, že  $\text{corr}(x, y) = 1$ . Potom

$$\text{Corr}(X, Y) = \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix}, \quad \text{Var}(X, Y) = \begin{pmatrix} \text{var } X & -\sqrt{\text{var } X \text{var } Y} \\ -\sqrt{\text{var } X \text{var } Y} & \text{var } Y \end{pmatrix}$$

Po vynásobení  $\text{Var}(X, Y)$  vektorem  $(\sqrt{\text{Var } Y}, \sqrt{\text{var } X})$  dostaneme nulový vektor, tedy matice je singulární. Proto  $\exists u, v \neq 0$  taková, že  $(u, v)^T \text{Var}(X, Y)(u, v) = 0$ , tedy  $\text{var}(uX + vY) = 0$ , neboli  $uX + vY$  je konstanta. Tím jsme jinak dokázali implikaci  $\Rightarrow$  v bodu 2 věty 23.

**Definice 24.** Náhodné veličiny  $X, Y$  takové, že  $\text{cov}(X, Y) = 0$  nazveme *nekorelované*.

Víme, že když jsou  $X, Y$  nezávislé, pak jsou  $X, Y$  nekorelované. Naopak to však obecně **neplatí!** Dobrým příkladem, proč to neplatí, jsou náhodné veličiny  $X, Y$ , kde  $Y = X^2$ .

## Transformace

Asi nejčastější transformace, kterou používáme, je  $\mathbf{X} \rightarrow \sum_{i=1}^d X_i$ .

Transformace je tedy zobrazení  $\varphi: \mathbb{R}^d \rightarrow \mathbb{R}^l$ . My potřebujeme, aby  $\varphi(\mathbf{X})$  byl opět náhodný vektor, který splňuje definici 17.

Mějme tedy vektor  $\mathbf{Y} = \varphi(\mathbf{X})$ . Jaké má tento vektor rozdělení?

**Věta 24.** *Bud'  $\mathbf{X}$   $d$ -rozměrný náhodný vektor a  $\varphi: \mathbb{R}^d \rightarrow \mathbb{R}^l$  (slušně vychovaná) funkce. Potom  $\mathbf{Y} = \varphi(\mathbf{X})$  s distribuční funkcí*

$$F_{\mathbf{Y}}(\mathbf{u}) = P_{\mathbf{X}} \left( \varphi^{-1} \left( \prod_{i=1}^l (-\infty, u_i] \right) \right).$$

*Je-li  $\mathbf{X}$  diskrétní náhodný vektor, pak  $\mathbf{Y}$  je též diskrétní náhodný vektor a*

$$P[\mathbf{Y} = \mathbf{u}] = \sum_{\mathbf{v}: \varphi(\mathbf{v}) = \mathbf{u}} P[\mathbf{X} = \mathbf{v}]$$

Máme tedy dva náhodné vektory  $\mathbf{X}: \Omega \rightarrow \mathbb{R}^d$  a  $\mathbf{Y}: \Omega \rightarrow \mathbb{R}^l$  takové, že  $\mathbf{Y} = \varphi(\mathbf{X})$ . Nás zajímá  $F_{\mathbf{Y}}(\mathbf{u}) = P(\{\omega: \mathbf{Y}(\omega) \leq \mathbf{u}\}) = P(\{\omega: \mathbf{Y}(\omega) \in A\}) = P(\{\omega: \mathbf{X}(\omega) \in \varphi^{-1}(A)\}) = P_{\mathbf{X}}(\varphi^{-1}(A))$ , kde  $A = \prod_{i=1}^l (-\infty, u_i]$ .

**Věta 25** (Rozdělení součtu a součinu diskrétního náhodného vektoru). *Bud'  $X, Y$  diskrétní náhodné veličiny (na stejném  $(\Omega, \mathcal{F}, P)$ ), pak:*

1.  $Z = X + Y$  je také diskrétní náhodná veličina a platí  $P[Z = v] = \sum_u P[X = u, Y = v - u]$ .
2. Pokud jsou  $X, Y$  kladné (tedy  $P[X > 0] = P[Y > 0] = 1$ ), pak  $V = XY$  je také kladná diskrétní náhodná veličina a  $P[V = z] = \sum_u P[X = u, Y = \frac{z}{u}]$ .

*pro obecné  $d, n, v$  je třeba dát pozor na  $ab = -(a)(-b)$  a  $0b = a0 = 0$ .*

*Důkaz.* Podle věty o úplné pravděpodobnosti  $P[Z = v] = \sum_u P[Z = v, X = u] = \sum_u P[X = u, X + Y = v] = \sum_u P[X = u, Y = v - u]$ . Druhý bod analogicky.

Pro více, než dvě veličiny můžeme postupovat indukcí. □

**Věta 26** (Momentová vytvořující funkce součtu). *Bud'  $X_1, \dots, X_n$  nezávislé náhodné veličiny a  $Y$  jejich součet. Pak*

$$\psi_Y(t) = \prod_{i=1}^n \psi_{X_i}(t).$$

*Důkaz.* Z nezávislosti plyne, že  $\psi_Y(t) = Ee^{tY} = Ee^{t \sum X_i} = E \prod e^{tX_i}$ . Z nezávislosti poté máme  $\prod \psi_{X_i}(t)$ . □

Mějme náhodný vektor  $\mathbf{X}$  a  $\mathbf{Y} = \varphi(\mathbf{X})$ . Chceme znát  $E\mathbf{Y}$ . Můžeme třeba určit rozdělení  $\mathbf{Y}$  a pak počítat střední hodnotu podle definice. Toto však nemusí být jednoduché.

Druhá možnost  $Eg(\mathbf{Y}) = Eg(\varphi(\mathbf{X})) = Eh(\mathbf{X})$ . Poté není třeba určovat rozdělení, je však potřeba najít  $h$ .

**Příklad.** Mějme  $Y = \sum_{i=1}^d X_i$ . Najít rozdělení součtu může být těžké a lze v něm nadělat spoustu chyb. Avšak  $E \sum_{i=1}^d X_i$  je vždy  $\sum_{i=1}^d EX_i$ , a to díky linearitě střední hodnoty (věta 20).

## 6 Absolutně spojitě náhodné vektory

Definice 17, TODO[18,19,20] zde stále platí.

**Definice 25** (Absolutně spojitý (AC) náhodný vektor). *Náhodný vektor  $\mathbf{X} = (X_1, \dots, X_d)$  je absolutně spojitý (nebo jeho rozdělení je absolutně spojitě), existuje-li nezáporná funkce  $f: \mathbb{R}^d \rightarrow \mathbb{R}$  taková, že*

$$F_{\mathbf{X}} = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(t_1, \dots, t_d) dt_d \dots dt_1$$

Funkce  $f$  se nazývá sdruženou hustotou rozdělení  $\mathbf{X}$ .

Pro diskrétní náhodný vektor jsme hustotou označovali  $p_{\mathbf{X}}(\mathbf{u}) = P[\mathbf{X} = \mathbf{u}]$ . Pro AC náhodný vektor však platí  $P[\mathbf{X} = \mathbf{u}] = 0 \forall \mathbf{u} \in \mathbb{R}^d$ .

Pravděpodobnost  $P[\mathbf{a} \leq \mathbf{X} \leq \mathbf{b}] = \int_{a_1}^{b_1} \cdots \int_{a_d}^{b_d} f(t_1, \dots, t_d) dt_d \cdots dt_1$ .

Zhruba řečeno  $f_{\mathbf{X}}(\mathbf{u}) \approx P[\mathbf{X} \in U(\mathbf{u}, \delta)]/|U(\mathbf{u}, \delta)|$ , kde  $U(\mathbf{u}, \delta)$  je dostatečně „malé“ okolí  $\mathbf{u}$ .

Jestliže máme  $f$  spojitou funkci, která se však nedá zapsat jako integrál, potom náhodné rozdělení definované touto funkcí je *singulárně spojité*. Takové rozdělení se však chová dost ošklivě.

V reálném světě nebude platit, že všechny vektory jsou buďto celé diskrétní, nebo absolutně spojité. Můžou existovat vektory se složkami různých „typů“, například vektor  $(X, Y)$ , kde  $X$  je diskrétní veličina, zatímco  $Y$  je spojitá.

**Příklad.** Představme si, že máme pozorování směru větru z meteorologie. Nejčastěji vítr fouká směrem na západ. Potom tento náhodný vektor není ani absolutně spojitý (nelze napsat četnost na kružnici jako integrál), ani diskrétní (plocha kružnice je nulová).

**Věta 27** (Marginální rozdělení AC náhodného vektoru). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  AC náhodný vektor se sdruženou hustotou  $f_{\mathbf{X}}$ . Pak marginální distribuční funkce  $F_{X_i}$  je daná*

$$F_{X_i}(t) = \int_{-\infty}^{\infty} \cdots \underbrace{\int_{-\infty}^t}_{i\text{-tý}} \cdots \int_{-\infty}^{\infty} f(u_1, \dots, u_d) du_d \cdots du_1 = \int_{-\infty}^t f_{X_i}(u) du$$

kde

$$f_{X_i}(u_i) = \underbrace{\int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty}}_{d-1 \text{ integrálů}} f(u_1, \dots, u_{i-1}, u_i, u_{i+1}, \dots, u_d) du_d \cdots du_{i+1} du_{i-1} \cdots du_1$$

je marginální hustota náhodné veličiny  $X_i$ .

*Důkaz.* Podle definice marginální funkce  $F_{X_i}(t) = \lim_{t_j \rightarrow \infty, j \neq i} F_{\mathbf{X}}(t_1, \dots, t_d)$ . Podle definice AC vektoru je to dále rovno  $\lim_{t_j \rightarrow \infty, j \neq i} \int_{-\infty}^{t_1} \cdots \int_{-\infty}^{t_{i-1}} \int_{-\infty}^{t_i} \int_{-\infty}^{t_{i+1}} \cdots \int_{-\infty}^{t_d} f_{\mathbf{X}}$  neklesající v  $t_j$  omezena shora 1. Tedy  $\lim F_{\mathbf{X}}(\mathbf{t}) = 1$ . Potom

$$\int_{-\infty}^{\infty} \cdots \int_{-\infty}^t \cdots \int_{-\infty}^{\infty} f_{\mathbf{X}} = \int_{-\infty}^t \underbrace{\int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} f_{\mathbf{X}}(u_1, \dots, u_d) du_d \cdots du_{i+1} du_{i-1} \cdots du_1}_{\geq 0} du_i$$

□

**Věta 28** (Nezávislost AC). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  AC náhodný vektor se sdruženou hustotou  $f_{\mathbf{X}}$ . Pak náhodné veličiny  $X_1, \dots, X_d$  jsou nezávislé právě tehdy, když*

$$f_{\mathbf{X}}(\mathbf{a}) = \prod_{i=1}^d f_{X_i}(a_i) \forall \mathbf{a} = (a_1, \dots, a_d) \in \mathbb{R}^d$$

Důkaz této věty vychází ze vztahu hustoty a rozdělení.

Náhodné rozdělení, distribuční funkci i hustotu umíme mezi sebou vyvodit. Také umíme vyvodit marginální distribuční funkci, naopak však ne.

**Věta 29** (Momenty AC náhodného vektoru). *Buď  $\mathbf{X} = (X_1, \dots, X_d)$  AC náhodný vektor se sdruženou hustotou  $f_{\mathbf{X}}$  a  $g: \mathbb{R}^d \rightarrow \mathbb{R}$ . Pak*

$$Eg(\mathbf{X}) = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} g(u_1, \dots, u_d) f_{\mathbf{X}}(u_1, \dots, u_d) du_d \cdots du_1$$

pokud tento integrál existuje. Speciálně pro  $g(\mathbf{X}) = X_1$  je

$$Eg(x) = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} u_1 f_{\mathbf{X}}(u_1, \dots, u_d) du_d \cdots du_1 = \int_{-\infty}^{\infty} u_1 f_{X_1}(u_1) du_1.$$

## Transformace

**Věta 30** (Konvoluce). *Bud'  $(X, Y)$  AC náhodný vektor s hustotou  $f_{(X, Y)}$ . Pak  $Z = X + Y$  je AC náhodná veličina a platí*

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

Tato věta je v podstatě spojitá verze diskrétního součtu.

*Důkaz.* Chceme najít  $P[Z \leq z] = P[X + Y \leq z] = P[(X, Y) \in H]$  kde  $H$  je polorovina rozdělená přímkou  $Z = X + Y$ . To se rovná  $\iint_H f_{(X, Y)}(u, v) dvdu = \int_{-\infty}^{\infty} \int_{-\infty}^{z-u} f_{(X, Y)}(u, v) dvdu = F_Z(z)$ .

Využijme vztahu distribuční funkce a hustoty:  $F_Z(z) = \int_{-\infty}^z f_Z(t) dt$ . Využijme vztah  $f_Z(z) = F'_Z(z)$ , který ale ne nutně pro všechny  $z$  platí, jelikož  $F_Z$  nemusí být derivovatelná. Těchto problematických bodů však není „mnoho“ a v nich můžeme  $f$  dodefinovat podle potřeby.

Potřebujeme tedy najít  $\frac{\partial}{\partial z} \int_{-\infty}^{\infty} \int_{-\infty}^{z-u} f_{(X, Y)}(u, v) dvdu$ . Tato derivace se prvního integrálu nedotýká, dostáváme se tedy na  $\int_{-\infty}^{\infty} \left( \frac{\partial}{\partial z} \int_{-\infty}^{z-u} f_{(X, Y)}(u, v) dv \right) du$ . Vnitřek můžeme zderivovat, kde získáme  $f_{(X, Y)}(u, z - u) \cdot 1$ . Dostáváme tedy výraz ve větě.  $\square$

**Věta 31** (Hustota podílu a součinu). *Bud'  $(X, Y)$  AC náhodný vektor s hustotou  $f_{(X, Y)}$  a nechť  $P[Y > 0] = 1$ . Pak  $V = \frac{X}{Y}$  je AC náhodná veličina s hustotou*

$$f_V(v) = \int_{-\infty}^{\infty} f_{(X, Y)}(vy, y) \cdot y dy.$$

Dále  $W = XY$  je AC náhodná veličina s hustotou

$$f_W(w) = \int_{-\infty}^{\infty} f_{(X, Y)}\left(\frac{w}{y}, y\right) \cdot \frac{1}{y} dy.$$

*Důkaz.* Chceme najít  $P[V \leq v] = P\left[\frac{X}{Y} \leq v\right] = P[X \leq vY] = P[(X, Y) \in H]$  kde  $H$  je polorovina rozdělená přímkou  $x = vY$ . Postupujeme tedy podobně, jako u předchozího důkazu.

Derivováním vnitřního integrálu tentokrát dostaneme  $F_{(X, Y)}(vy, y) \cdot y = \frac{\partial(vy)}{\partial y}$ .

Hustotu součinu dostaneme přímým dosazením obrácené hodnoty  $Y$  do podílu.  $\square$

**Normální rozdělení** (taky Gaussovo, či po Germánsku Gaußovo)

Zapíše se  $X \sim N(0, 1)$  ( $X$  má normální rozdělení s parametry 0 a 1).

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

Dále vezměme si  $Y = \mu + \sigma X$ , potom  $f_Y(y) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-\mu)^2}{2\sigma^2}}$ . Dále  $EY = \mu$ ,  $\text{var } Y = \sigma^2$ .

Pokud máme  $Z \sim N(\mu, \sigma^2)$ , potom normované či standardní rozdělení je  $\frac{Z-\mu}{\sigma} \sim N(0, 1)$ .

**Mnohorozměrné normální rozdělení**

1. Mějme  $X, Y \sim N(0, 1)$ , které jsou navzájem nezávislé. Potom  $f_{X, Y} = \frac{1}{2\pi} e^{-\frac{x^2+y^2}{2}}$ .

2. Mějme  $X \sim N(\mu_1, \sigma_1^2)$  a  $Y \sim N(\mu_2, \sigma_2^2)$ , které jsou nezávislé.  $f_{X, Y} = \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2}} \exp\left(-\frac{(x-\mu_1)^2}{2\sigma_1^2} - \frac{(y-\mu_2)^2}{2\sigma_2^2}\right)$ .

Dále  $\text{Var}(X, Y) = \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{pmatrix} = \Sigma$ .

Potom  $\det \Sigma = \sigma_1^2 \sigma_2^2$  a  $\Sigma$  je nějaká kvadratická forma, tedy

$$f_{X, Y}(x, y) = \frac{1}{2\pi\sqrt{\det \Sigma}} \exp\left(-\frac{1}{2}(x - \mu_1, y - \mu_2)^T \Sigma^{-1}(x - \mu_1, y - \mu_2)\right).$$

Tato hustota lze definovat pro libovolnou  $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$  symetrickou pozitivně definitní. Potom  $EX = \mu_1$ ,  $EY = \mu_2$ ,  $\text{var } X = \sigma_1^2$ ,  $\text{var } Y = \sigma_2^2$ ,  $\text{corr}(X, Y) = \rho$ .

Tato definice lze zobecnit na  $d$  rozměrů. Mějme  $\Sigma^{d \times d}$  symetrickou pozitivně definitní,  $\boldsymbol{\mu} \in \mathbb{R}^d$ . Potom  $f_{\mathbf{X}}(\mathbf{u}) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{\det \Sigma}} \exp\left\{-\frac{1}{2}(\mathbf{u} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{u} - \boldsymbol{\mu})\right\}$ .

V tomto náhodném vektoru je potom  $\text{Var } \mathbf{X} = \Sigma$ ,  $E\mathbf{X} = \boldsymbol{\mu}$ . Každé marginální rozdělení bude také odpovídat normálnímu rozdělení.

Normální rozdělení je jediné absolutně spojitě rozdělení, kde platí, že když  $(X, Y) \sim N_2(\dots)$  a  $\text{cov}(X, Y) = 0$ ,  $X, Y$  jsou nezávislé.

## 7 Podmíněné rozdělení a podmíněná střední hodnota

**Definice 26** (Podmíněné rozdělení diskretního náhodného vektoru). Buď  $X = (Y, Z)$  diskretní náhodný vektor (s hodnotami v  $\mathbb{N}_0^2$ ). Pak pro každé  $n \in N_0$  takové, že  $P[Z = n] > 0$  definujeme podmíněné rozdělení  $Y$  za podmínky  $Z = n$ :

$$P[Y = k|Z = n] = \frac{P[Y = k, Z = n]}{P[Z = n]}.$$

Podmínku  $Z = n$  chápeme jako další informaci o chování náhodné veličiny  $Y$ , dává nám na něj přesnější pohled, platí-li podmínka.

**Příklad.** Mějme 6 mincí a jednu kostku. Hodíme kostkou a podle výsledku hodíme odpovídající počet mincí. Jaká je pravděpodobnost, že nepadne žádný líc?

Jaké je rozdělení počtu líců? Víme, že počet líců je  $0, \dots, 6$ . To však nedokážeme spočítat přímo, musíme vždy spočítat rozdělení za podmínky hození kostkou.

**Definice 27** (Podmíněná střední hodnota). Buď  $X = (Y, Z)$  diskretní náhodný vektor takový, že

1.  $P[Z = n] > 0$
2.  $Eg(Y, n) < \infty$  pro zvolenou funkci  $g$ .

Pak definujeme  $Eg(Y, Z|Z = n) = \sum_{k=0}^{\infty} g(k, n)P[Y = k|Z = n]$ .

Speciálně, pokud  $E|Y| < \infty$ , potom  $E(Y|Z = n) = \sum_{k=0}^{\infty} kP[Y = k|Z = n]$ . a zveeme toto *podmíněnou střední hodnotu*  $g(Y, Z)$  za podmínky  $Z = n$ .

**Věta 33** (O úplné střední hodnotě). Buď  $X = (Y, Z)$  diskretní náhodný vektor a  $EY$  existuje konečná. Pak

$$EY = \sum_n E[Y|Z = n]P[Z = n]$$

pro ta  $n$ , pro které  $P[Z = n] > 0$ .

*Důkaz.* Začneme s pravou stranou.  $\sum_n E[Y|Z = n]P[Z = n] = \sum_n \sum_{k=0}^{\infty} kP[Y = k|Z = n]P[Z = n] = \sum_n \sum_{k=0}^{\infty} kP[Y = k, Z = n]$ . Jelikož počítáme s existující  $EY$ , můžeme dále pokračovat na  $\sum_{k=0}^{\infty} k \sum_n P[Y = k, Z = n] = EY$ .  $\square$

Všimněme si, že podmíněná střední hodnota je konstanta závislá na  $n$  a při sečtení všech  $n$  dostaneme přímou střední hodnotu  $EY$ , která je již konstantní v daném rozdělení.

Můžeme si také všimnout, že podmíněná pravděpodobnost nám faktoruje množinu  $\Omega$  podle hodnoty  $z$ . Na této faktorové množině poté můžeme zavést novou náhodnou veličinu se zajímavými vlastnostmi.

**Definice 28** (Podmíněná střední hodnota jako náhodná veličina). Buď  $X = (Y, Z)$  diskretní náhodný vektor,  $E|Y| < \infty$ . Definujeme náhodnou veličinu  $E(Y|Z)$  předpisem  $E(Y|Z)(\omega) = E(Y|Z = n) \forall \omega \in \{\omega : Z(\omega) = n\}$ .

Rozdělení této náhodné veličiny je zřejmě  $P[E(Y|Z) = E(Y|Z = n)] = P[Z = n]$ .

$EY$  má tuto vlastnost:  $E(Y - EY)^2 = \min_{a \in \mathbb{R}} E(Y - a)^2$ . Střední hodnota je tedy nejlepší konstanta, která reprezentuje nejmenší čtvercovou chybu.

Na množině  $\{\omega : Z(\omega) = n\}$  platí  $E(Y - E(Y|Z = n))^2 = \min_{b \in \mathbb{R}} E(Y - b)^2$ . Můžeme tedy najít ještě lepší konstantu, než  $EY$ , reprezentující tuto informaci.

**Věta 34.** Buď  $X = (Y, Z)$  diskretní náhodný vektor,  $E|Y| < \infty$ . Pak  $E(E(Y|Z)) = EY$ .

*Důkaz.* Přímý důsledek věty 33.  $\square$

**Poznámka** (Podmíněný rozptyl).  $\text{var}(Y|Z = n) = E\left((Y - E(Y|Z = n))^2 \mid Z = n\right)$

**Definice 29** (Podmíněná hustota). Buď  $X = (Y, Z)$  absolutně spojitý náhodný vektor se sdruženou hustotou  $f_{Y,Z}$ . Definujme  $f_{Y|Z}(v|w)$  předpisem:

$$f_{Y|Z}(v|w) = \begin{cases} \frac{f_{Y,Z}(v,w)}{f_Z(w)} & f_Z(w) > 0 \\ 0 & \text{jinak} \end{cases}$$

kterouž funkci nazveme hustotou podmíněného rozdělení  $Y$  za podmínky  $Z = w$ .

Nyní pojďme ověřit, že takto definovaná hustota je opravdu hustotou.

Marginální hustota  $f_Z = \int_{-\infty}^{\infty} f_{Y,Z}(v, w) dv$ . Pokud je rovna nule, potom  $f_{Y,Z}(v, w) = 0$ .

Nyní  $\int_{-\infty}^{\infty} f_{Y|Z}(v|w) dv = \int \frac{f_{Y,Z}(v,w)}{f_Z(w)} = \frac{f_Z(w)}{f_Z(w)}$ , kdykoliv  $f_Z(w) > 0$ .

$P[Y \in A, Z \in B] = \int_A \int_B f_{Y,Z}(v, w) dw dv = \int_A \int_B f_{Y|Z}(v|w) f_Z(w) dw dv = \int_B \left( \int_A f_{Y|Z}(v|w) dv \right) f_Z(w) dw$ . Zde můžeme vidět náznaky věty o úplné pravděpodobnosti pro absolutně spojitý náhodný vektor.

**Definice 30** (Podmíněná střední hodnota). Buď  $X = (Y, Z)$  absolutně spojitý náhodný vektor,  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$  taková, že  $E|G(Y, w)| < \infty$ . Pak definujeme  $E(g(Y, Z)|Z = w) = \int_{-\infty}^{\infty} g(v, w) f_{Y|Z}(v|w) dv$  a  $E(Y|Z = w) = \int_{-\infty}^{\infty} v f_{Y|Z}(v|w) dv$ .

## 8 Nerovnosti a meze

Nerovnosti se hodí k odhadování určování pravděpodobností určitých jevů či veličin.

**Věta 35** (Markovova nerovnost). *Buď  $X$  nezáporná náhodná veličina. Potom*

$$P[X \geq \varepsilon] \leq \frac{EX}{\varepsilon} \quad \forall \varepsilon > 0$$

*Důkaz.*  $[X \geq \varepsilon] = P\{\omega : X(\omega) \geq \varepsilon\} = \int_{\omega: X(\omega) \geq \varepsilon} 1 dP \leq \int_{\omega: X(\omega) \geq \varepsilon} \frac{X(\omega)}{\varepsilon} \text{Vždy kladné} dP \leq \int_{\Omega} \frac{X(\omega)}{\varepsilon} dP = \frac{EX}{\varepsilon}$ .  $\square$

**Věta 36** (Markovova nerovnost podruhé). *Buď  $X$  nezáporná náhodná veličina. Potom*

$$P[X \geq \varepsilon] \leq \frac{E(X^k)}{\varepsilon^k} \quad \forall \varepsilon > 0, k > 0$$

*Důkaz.* Jediná změna oproti předchozímu:  $X(\omega) \geq \varepsilon \Rightarrow \left(\frac{X(\omega)}{\varepsilon}\right)^k \geq 1$ . Jinak stejně.  $\square$

**Věta 37** (Čebyševova nerovnost). *Buď  $X$  náhodná veličina a  $E|X| < \infty$ . Pak*

$$P[|X - EX| \geq \varepsilon] \leq \frac{\text{var } X}{\varepsilon^2}$$

*Důkaz.* Věta 36 použitá na  $|X - EX|$  a  $k = 2$ .  $\square$

Pojďme si na chvíli povídat o náhodných procházkách. Představme si, že jsme zrovna vyšli z hospůdky ve tři ráno a náhodně v ulicích jdeme na sever nebo na jih pár minut. Kam až se můžeme dostat? Za jak dlouho se vrátíme zpět k hospodě, abychom tam strávili čas tentokrát až do rána?

Mějme  $X_1, X_2, \dots$  nezávislé, jejichž pravděpodobnosti jsou  $P[X_i = 1] = P[X_i = -1] = \frac{1}{2}$ . Dále mějme  $S_k = \sum X_i$ . Čebyševova nerovnost říká  $P[|S_n - ES_n| \geq \varepsilon] \leq \frac{\text{var } S_n}{\varepsilon^2}$ .

Spočteme nyní  $ES_k = \sum EX_i = 0$  a  $\text{var } S_k = \text{var} \sum S_i = \sum \text{var } S_i = k$ .

Podle nerovnosti tedy dostáváme, že  $P[|S_n| \geq \varepsilon] \leq \frac{n}{\varepsilon^2}$ . Dále  $P[|S_n| \geq 2\sqrt{n}] \leq \frac{n}{4n} \leq \frac{1}{4}$ .

**Věta 38** (Kolmogorovova nerovnost). *Buďte  $X_1, X_2, \dots$  nezávislé náhodné veličiny a  $E|X_i| < \infty \forall i$ . Pak*

$$P \left[ \max_{1 \leq k \leq n} \left| \sum_{i=1}^k (X_i - EX_i) \right| \geq \varepsilon \right] \leq \frac{\sum_{i=1}^n \text{var } X_i}{\varepsilon^2}$$

*Důkaz.* Označme si  $S_k = \sum_{i=1}^k (X_i - EX_i)$ . Potom  $ES_k = 0$  a  $\text{var } S_k = \sum_{i=1}^k \text{var } X_k$  díky nezávislosti. Hledáme tedy pravděpodobnost  $P[\max_{1 \leq k \leq n} |S_k| \geq \varepsilon]$ .

Zdefinujeme si množinu  $A_k = \{\omega : |S_j(\omega)| < \varepsilon, j < k, |S_k(\omega)| \geq \varepsilon\}$  a  $S_0 = 0$ . Můžeme si všimnout, že  $A_k$  jsou po dvou disjunktí. Rozložili jsme pravděpodobnostní prostor podle prvního překročení  $\varepsilon$ .

Potom  $P[\max_{1 \leq k \leq n} |S_k| \geq \varepsilon] = P[\bigcup_{k=1}^n A_k] = \int_{\bigcup_{k=1}^n A_k} 1 dP = \sum_{k=1}^n \int_{A_k} 1 dP \leq \sum_{k=1}^n \int_{A_k} \frac{S_k^2(\omega)}{\varepsilon^2} dP$ .

Dále  $\int_{A_k} S_k^2(\omega) dP = \int_{A_k} (S_n - S_k + S_k)^2 dP = \int_{A_k} (S_n - S_k)^2 dP + \int_{A_k} 2(S_n - S_k) \cdot S_k dP + \int_{A_k} (S_k)^2 dP$ .

Z toho se podívejme na  $\int_{A_k} 2(S_n - S_k) \cdot S_k dP = \int_{\Omega} (S_n - S_k)(S_k \chi_{A_k}) dP = E((S_n - S_k) \cdot S_k \cdot \chi_{A_k})$ . Využijme nezávislosti a toho, že  $S_n - S_k = X_{k+1} + X_{k+2} + \dots + X_n$  a  $S_k = X_1 + X_2 + \dots + X_k$  a  $A_{A_k}$  závisí jen na  $(X_1, \dots, X_k)$ . Tedy celý integrál se rovná  $E(S_n - S_k)ES_k \chi_{A_k} = 0$ .

Tedy  $\sum_{k=1}^n \int_{A_k} \frac{S_k^2(\omega)}{\varepsilon^2} dP \leq \int_{A_k} \frac{S_n^2(\omega)}{\varepsilon^2} dP$ , kde potom můžeme postupovat jako u předchozích nerovností.  $\square$

**Věta 39** (Chernoffovy meze). *Bud'  $X$  náhodná veličina. Označme  $\psi_X(t) = Ee^{tX}$  její momentovou vytvořující funkci. Pak*

$$P[X \geq a] \leq \min_{t>0} \frac{\psi_X(t)}{e^{ta}}, P[X \leq A] \leq \min_{t<0} \frac{\psi_X(t)}{e^{ta}}$$

*Důkaz.* Pro první mez  $P[X \geq a] = P[e^{tX} \geq e^{ta}]$  pro  $t > 0$ . Dostali jsme nezápornou veličinu, využijeme Markovovu nerovnost, tedy  $P[e^{tX} \geq e^{ta}] \leq \frac{Ee^{tx}}{e^{ta}} \forall t > 0$ . Z toho potom jen vybereme minimum.

Druhá mez analogicky.  $P[X \leq a] = P[e^{tX} \geq e^{ta}] \leq \frac{Ee^{tx}}{e^{ta}}$  pro  $t < 0$ . □

**Definice 31** (Poissonovské pokusy). *Bud'te  $X_1, X_2, \dots$  nezávislé náhodné veličiny takové, že  $P[X_i = 1] = p_i = 1 - P[X_i = 0], p_i \in (0, 1)$ . Takové pokusy se nazývají nezávislé poissonovské pokusy.*

Jestliže u poissonovských pokusů bude každé  $p_i = p$  pro nějaké konstantní  $p$ , dostaneme bernoulliiovské pokusy.

**Věta 40** (Horní Chernoffovy meze pro poissonovské pokusy). *Bud'te  $X_1, X_2, \dots$  nezávislé poissonovské pokusy s parametry  $p_1, p_2, \dots$ . Označme  $S_n = \sum_{i=1}^n X_i, \mu_S = \sum_{i=1}^n p_i$ .*

1. Pro  $\delta > 0$ :

$$P[S_n \geq (1 + \delta)\mu_s] \leq \left( \frac{e^\delta}{(1 + \delta)^{(1 + \delta)}} \right)^{\mu_s}$$

2. Pro  $0 < \delta \leq 1$ :

$$P[S_n \geq (1 + \delta)\mu_s] \leq e^{-\mu_s \delta^2 / 3}$$

3. Pro  $\delta > 6\mu_s$ :

$$P[S_n > \delta] \leq 2^{-\delta}$$

*Důkaz.* Jen první.  $P[S_n \geq (1 + \delta)\mu_s] \leq \frac{\psi_{S_n}(t)}{e^{t(1 + \delta)\mu_s}}$ .

Z nezávislosti a věty 26 dostáváme  $\psi_{S_n} = \prod_{i=1}^n \psi_{x_i}(t)$  a  $\psi_{x_i}(t) = Ee^{tX_i} = p_i e^t + (1 - p_i) = 1 + p_i(e^t - 1)$ .  
Dále  $\prod_{i=1}^n (1 + p_i(e^t - 1)) = \exp\{\sum_{i=1}^n \log(1 + p_i(e^t - 1))\} \leq \exp\{(e^t - 1) \sum_{i=1}^n p_i\} = \exp\{(e^t - 1)\mu_s\}$ .

Dosadíme do vzorce, dostáváme  $\frac{\prod_{i=1}^n (1 + p_i(e^t - 1))}{e^{t(1 + \delta)\mu_s}} \leq \frac{\exp\{(e^t - 1)\mu_s\}}{\exp t(1 + \delta)\mu_s} = \exp \mu_s (e^t - 1 - t(1 + \delta))$ .

Nakonec  $P[S_n \geq (1 + \delta)\mu_s] \leq \frac{\prod_{i=1}^n (1 + p_i(e^t - 1))}{e^{t(1 + \delta)\mu_s}} = \exp \mu_s [\delta - \log(1 + \delta)^{1 + \delta}] =$  hledaný výraz. □

## 9 Náhodné výběry a limitní věty

Na této přednášce jsem z nemoci chyběl, proto může pár věcí chybět.

**Definice 32** (Množinový lim sup a lim inf). *Bud'  $A_n, n = 1, 2, \dots$  množiny (náhodné jevy). Definujme*

$$\limsup_{n \rightarrow \infty} A_n = \bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i \quad \liminf_{n \rightarrow \infty} A_n = \bigcup_{n=1}^{\infty} \bigcap_{i=n}^{\infty} A_i$$

Jestliže  $a \in \limsup_{n \rightarrow \infty} A_n$ , potom existuje nekonečně mnoho množin  $A_i$ , kde  $a \in A_i$ . Jestliže  $b \in \liminf_{n \rightarrow \infty} A_n$ , potom existuje nejvýše konečně mnoho množin  $A_i$ , kde  $b \notin A_i$ .

**Věta 42** (Borel-Cantelliho 0-1 pravidlo). 1. *Bud'  $A_n, n = 1, 2, \dots$  náhodné události. Pak*

$$\sum_{i=1}^{\infty} P(A_i) < \infty \Rightarrow P\left(\limsup_{n \rightarrow \infty} A_n\right) = 0.$$

2. *Bud'  $A_n, n = 1, 2, \dots$  nezávislé náhodné události. Potom*

$$\sum_{i=1}^{\infty} P(A_i) = \infty \Rightarrow P\left(\limsup_{n \rightarrow \infty} A_n\right) = 1.$$

Všimněme si, že  $\liminf A_n = (\limsup A_n^C)^C$ . Z tohoto důvodu můžeme ve větě 42 používat jak lim sup, tak i lim inf.

**Definice 33** (Náhodný výběr). *Posloupnost  $X_1, X_2, \dots$  náhodných veličin či vektorů takových, že jsou nezávislé, identicky rozložené, nazvěme náhodný výběr velikosti  $n$  náhodného rozložení  $P_X$ .*



**Definice 34** (Výběrové momenty). Buď  $X_1, \dots, X_n$  náhodný výběr. Potom

1.  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  se nazývá *výběrový průměr*.
2.  $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  se nazývá *výběrový rozptyl*.
3.  $\widehat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \chi(X_i \leq x)$ , kde  $\chi$  je indikátorová funkce, se nazývá *empirická distribuční funkce*.

**Věta 43** ((Slabý) Zákon velkých čísel). Buď  $X_1, X_2, \dots$  nezávislé a identicky rozložené náhodné veličiny s konečným průměrem  $EX_1 = \mu$  a konečným rozptylem  $\text{var } X_1 = \sigma^2$ . Potom

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

*Důkaz.* Vidíme, že střední hodnota z průměru  $E\bar{X}_n = E\frac{1}{n} \sum X_i = \frac{1}{n} \sum EX_i = \mu$ . Využijme nyní Čebyševu nerovnost, tedy  $P[|\bar{X}_n - \mu| > \varepsilon] \leq \frac{\text{var } \bar{X}_n}{\varepsilon^2}$ .

Podívejme se nyní na  $\text{var } \bar{X}_n = \text{var } \frac{1}{n} \sum X_i = \frac{1}{n^2} \text{var } \sum X_i$ . Díky nezávislosti získáme  $\frac{1}{n^2} \text{var } \sum X_i = \frac{1}{n^2} \sum \text{var } X_i + \frac{1}{n^2} \sum_{i \neq j} \text{cov}(X_i, X_j)$ . Jelikož jsou každé  $X_i$  nekorelované, druhá suma je nulová, zatímco ta první limitně konverguje k 0.  $\square$

Tato vlastnost se nazývá (slabá) konzistence výběrového průměru. Předpoklad  $\sigma^2 < \infty$  se zdá příliš silný. Dal by se oslabit, ale potom by byl důkaz mnohem složitější. Tuto vlastnost nadále budeme označovat jako  $\bar{X}_n - \mu \xrightarrow{P} 0$  nebo  $\bar{X}_n \xrightarrow{P} \mu$ .

**Příklad.** Mějme alternativní rozdělení v  $n$  pokusech, každý pokus nastává s pravděpodobností  $p$ . Potom výběrový průměr je počet úspěchů v  $n$  pokusech a střední hodnota je  $p$ .

Relativní počet úspěchů tedy díky zákonu velkých čísel konverguje k  $p$ .

**Věta 44** (Konzistence empirické distribuční funkce). Buď  $X_1, X_2, \dots$  nezávislé a identicky rozložené náhodné veličiny s distribuční funkcí  $F_X$ . Pak pro každé  $x$  platí

$$P \left[ \left| \widehat{F}_n(x) - F_X(x) \right| > \varepsilon \right] \rightarrow 0 \text{ pro } n \rightarrow \infty.$$

**Příklad.** Máme  $X$  s neznámým rozdělením. Chceme určit  $P[0 < X < 1]$ . Potřebujeme náhodný výběr  $X_1, X_2, \dots$  s tímto neznámým náhodným rozdělením a víme, že  $\widehat{F}_n(1) \rightarrow F_X(1)$  a  $\widehat{F}_n(0) \rightarrow F_X(0)$ . Tedy  $P[0 < x \leq 1] = F_X(1) - F_X(0)$ . Dále  $\chi(x \leq a)$  dává jedničku, pokud je  $x \leq a$ , jinak nulu.

Proto  $\widehat{F}_n(1) - \widehat{F}_n(0) = \frac{1}{n} \sum \chi(0 < X \leq 1) \xrightarrow{P} P[0 < X \leq 1]$ .

*Důkaz.* Podívejme se na střední hodnotu a rozptyl odhadu  $\widehat{F}_n(x)$ . Tedy  $E\widehat{F}_n(x) = E\frac{1}{n} \sum \chi(X_i \leq x) = \frac{1}{n} \sum E\chi(X_i \leq x) = E\chi(X_1 \leq x)$ . Dále  $\chi(X \leq x) = 0$  s pravděpodobností  $F(x)$  a 1 s pravděpodobností  $1 - F(x)$ . Máme tedy Bernoulliho náhodný pokus se střední hodnotou  $F(x)$ . Tedy  $E\chi(X_1 \leq x) = F(x)$  a  $\text{var } \chi(X_1 \leq x) = F(x)(1 - F(x))$ .

Využijme nyní Čebyševu nerovnost.  $P[|\widehat{F}_n(x) - F(x)| > \varepsilon] \leq \frac{\text{var } \widehat{F}_n(x)}{\varepsilon^2} = \frac{1}{n\varepsilon^2} F(x)(1 - F(x))$ , což pro  $n \rightarrow \infty$  konverguje k nule.  $\square$

Předchozí věta platí dokonce i rovnoměrně, tedy  $P \left[ \sup_x \left| \widehat{F}_n(x) - F_X(x) \right| > \varepsilon \right] \rightarrow 0$ .

**Věta 45** (Centrální limitní věta). Buď  $X_1, X_2, \dots$  nezávislé a identicky rozložené náhodné veličiny s konečným průměrem  $EX_1 = \mu$  a konečným kladným rozptylem  $\text{var } X_1 = \sigma^2 > 0$ . Pak

$$P \left[ \sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \leq x \right] \rightarrow \Phi(x)$$

kde  $\Phi$  je distribuční funkce standardního normálního rozdělení  $N(0, 1)$ .

Stejně tak můžeme říct

$$\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \xrightarrow{d} N(0, 1) \text{ nebo } \frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n}\sigma} \xrightarrow{d} N(0, 1) \text{ nebo } \sqrt{n} (\bar{X}_n - \mu) \xrightarrow{d} N(0, \sigma^2).$$

**Příklad.** Podívejme se na využití Centrální limitní věty.

1. Chceme vědět, s jakou pravděpodobností bude počet úspěchů v Bernoulliových pokusech vyšší, než  $a$ . Máme  $X_1, \dots, X_n$  nezávislé stejnoměrně rozdělené s alternativním rozdělením parametru  $p$ . Kolik bude  $P[\sum X_i > a]$ ?

Použijeme Centrální limitní větu a použijeme stejné úpravy na obě strany:

$$P[\sum X_i > a] = P\left[\frac{\sum X_i - np}{\sqrt{np(1-p)}} > \frac{a - np}{\sqrt{np(1-p)}}\right] = P[\dots < \dots] \approx \Phi\left(\frac{a - np}{\sqrt{np(1-p)}}\right)$$

2. Určení počtu pokusů. Chceme vědět, kolik pokusů máme udělat, aby se relativní počet úspěchů v Bernoulliových pokusech (tedy podíl úspěchů k počtu pokusů) lišil od teoretické pravděpodobnosti nejvýše o  $\varepsilon$  s pravděpodobností nejvýše  $\alpha$ . Tedy hledáme  $n$  tak, aby  $P[|\bar{X}_n - p| > \varepsilon] \leq \alpha$ .

Znova využijeme CLV a upravujeme. Úpravou dostaneme

$$P\left[\sqrt{n} \frac{|\bar{X}_n - p|}{\sqrt{p(1-p)}} > a\right] = 1 - P[\dots \leq a] = 1 - (P[\dots \leq a] - P[\dots \leq -a]) = 1 - (\Phi(a) - \Phi(-a)).$$

To znamená, že hledáme  $a = \frac{\sqrt{n\varepsilon}}{\sqrt{p(1-p)}}$  tak, aby  $1 - (\Phi(a) - \Phi(-a)) \leq \alpha$ , tedy  $\Phi(a) - \Phi(-a) \geq 1 - \alpha$ . Víme, že  $\Phi(-a) = 1 - \Phi(a)$ , z toho dostáváme, že  $2\Phi(a) \geq 2 - \alpha$ , tedy  $a \geq \Phi^{-1}\left(1 - \frac{\alpha}{2}\right)$ . Z  $a$  potom získáme  $n$ .

**Věta 46 (Delta).** *Bud'  $Y_1, Y_2, \dots$  posloupnost náhodných veličin takových, že  $\sqrt{n}(Y_n - \mu) \xrightarrow{d} N(0, \sigma^2)$  a diferencovatelnou funkcí  $g$ . Pak*

$$\sqrt{n}(g(Y_n) - g(\mu)) \xrightarrow{d} N(0, (g'(\mu))^2 \sigma^2)$$

Delta věta se používá, když chceme asymptotickou normalitu nějaké diferencovatelné transformace normálního rozdělení.

**Příklad.** Předpokládejme, že máme Poissonovo rozdělení s parametrem  $\lambda$ . Pak víme, že  $EX = \text{var } X = \lambda$ . Z CLV víme, že  $\sqrt{n}(\bar{X}_n - \lambda) \xrightarrow{d} N(0, \lambda)$ . Dále víme, že  $P[X = 0] = e^{-\lambda} = g(\lambda)$ .

Delta věta říká  $\sqrt{n}(e^{-\bar{X}_n} - e^{-\lambda}) \xrightarrow{d} N(0, \lambda(g'(\lambda))^2) = N(0, \lambda e^{-2\lambda})$ .

**Věta 47 (Cramér–Slutskij).** *Bud'  $X_n \xrightarrow{d} N(\mu, \sigma^2)$ ,  $U_n \xrightarrow{P} a$  a  $Z_n \xrightarrow{P} s > 0$ . Pak*

$$Z_n X_n + U_n \xrightarrow{d} N(s\mu + a, s^2 \sigma^2)$$

Cramér–Slutskij a Delta věty jsou základní nástroje pro asymptotické odhadovací techniky založené na CLV. Z věty C–S vyplývá, že konvergence  $\xrightarrow{d}$  je slabší, než konvergence  $\xrightarrow{P}$ .

Tato věta se nejčastěji používá, když neznáme rozptyl nebo je práce s rozptylem příliš obtížná. V tom případě potom víme, že díky CLV  $\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \xrightarrow{d} N(0, 1)$  a také ze zákona velkých čísel  $\frac{S_n}{\sigma} \xrightarrow{P} 1$  pokud  $0 < \sigma^2 < \infty$ .

Díky C–S větě pak  $\frac{(\sqrt{n} \cdot \bar{X}_n - \mu)/\sigma}{S_n/\sigma} = \sqrt{n} \frac{\bar{X}_n - \mu}{S_n} \xrightarrow{d} N(0, 1)$ , tedy jsme nahradili rozptyl jeho výběrovým odhadem.

## 10 Bodové a intervalové odhady, hypotézy

Jedním ze základních úkolů statistiky je udělat nějaký (dobrý) odhad.

Představme si, že máme pokus, jehož výsledkem může být  $0, \dots, n$ . Udělali jsme tedy  $n$  pokusů, zajímá nás  $P[X = k]$ . Jednou z možností je sestavit empirickou distribuční funkci, která bude po částech skoková. Tyto odhady nejsou ideální ani přesné, musíme odhadovat  $n + 1$  hodnot.

Představme si ale, že předem víme, že  $x \sim \text{Bi}(n, p)$ . Již známe  $n$ , stačí nám odhadnout pouze jeden parametr  $p$ , potom náhodné rozdělení již známe.

**Definice 35 (Parametrické třídy).** Parametrickou třídou nazveme  $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$ , kde  $\Theta \subset \mathbb{R}^d$  je prostor parametrů a  $P_\theta$  je rozdělení náhodné veličiny (vektoru) známé až na parametr  $\theta$ .

**Příklad.**

- $\text{Bi}(n, p)$ , rozdělení  $P[X = k] = \binom{n}{k} p^k (1-p)^{n-k}$ . Potom  $\Theta = (0, 1)$  a  $p$  je neznámá.
- $N(\mu, \sigma^2)$  s hustotou  $\frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$ , potom  $\Theta = \mathbb{R} \times (0, \infty)$  a parametry jsou  $(\mu, \sigma^2)$ .
- Exponenciální rozdělení s hustotou  $f(x) = \lambda e^{-\lambda(x-a)}$ , potom  $\Theta = (0, \infty) \times \mathbb{R}$ , parametry  $(\lambda, a)$ .

**Definice 36** (Bodový odhad). Buď  $X_1, X_2, \dots, X_n$  náhodný výběr s rozdělením  $P_\theta$  z parametrické třídy  $\mathcal{P}$  a s  $\theta$  neznámým parametrem. Bodovým odhadem  $\theta$  je funkce  $T: \mathbb{R}^n \rightarrow \Theta$ ,  $T(X_1, \dots, X_n) \rightarrow \dots$ , její předpis nezávisí na parametru  $\theta$ .

Úkolem je najít  $T$ , které „dobře“ aproximuje  $\theta$ , dále:

1. Bodový odhad  $T$  nazveme nestranným, pokud  $\forall \theta \in \Theta$  platí  $ET = \theta$  je-li  $\theta$  skutečnou hodnotou parametru.
2. Bodový odhad  $T$  je konzistentní, pokud  $\forall \theta \in \Theta$  platí  $P[T - \theta] > \varepsilon \rightarrow 0$  je-li  $\theta$  skutečnou hodnotou parametru. (Tedy  $T \xrightarrow{P} \theta$ ).

Máme-li více konzistentních odhadů, chceme vybrat ten s nejmenším rozptylem. Není však zaručeno, aby existoval stejnoměrně nejlepší odhad.

Čím máme větší náhodný výběr, tím je odhad  $T$  přesnější. To nám zaručuje právě konzistence  $T$ .

Malá odbočka do angličtiny. „Estimator“ znamená funkci  $T$ , zatímco „Estimate“ je už konkrétní hodnota  $T(X_1, \dots, X_n)$ .

Jak získat bodový odhad? Existuje na to mnoho způsobů:

**Definice 37** (Metoda momentů). Buď  $P_\theta \in \mathcal{P}$  a úlohu najít bodový odhad  $\theta$ . Předpokládejme, že momenty  $EX^j = h_j(\theta)$ ,  $j = 1, 2, \dots$ . Potom řešení rovnic

$$\underbrace{\frac{1}{n} \sum_{i=1}^n X_i^j}_{\text{Výběrový moment}} = \underbrace{h_j(\theta)}_{\text{Skutečný moment}}, \quad j = 1, \dots, \dim(\Theta)$$

nazveme odhad metodou momentů.

**Příklad.** Mějme normální rozdělení. Potom  $EX = \mu = h_1(\mu, \sigma^2)$  a  $EX^2 = \sigma^2 + \mu^2 = h_2(\mu, \sigma^2)$ . Odhad je poté  $\hat{\mu} = \bar{X}_n$  a  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2$ .

Ze zákona velkých čísel potom  $\bar{X}_n \xrightarrow{P} \mu$ ,  $\frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow EX^2$ , tedy odhad  $\hat{\sigma}^2 \rightarrow \text{var } X$ .

Bodový odhad jde však zlepšit odhadem intervalovým, který je ale složitější.

**Definice 38** (Intervalový odhad). Buď  $X_1, \dots, X_n$  náhodný výběr z  $P_\theta$ ,  $\theta$  neznámý parametr a  $\Theta \subset \mathbb{R}$ . Intervalovým odhadem nazveme dvojici funkcí  $L(X_1, \dots, X_n) \rightarrow \mathbb{R}$  a  $U(X_1, \dots, X_n) \rightarrow \mathbb{R}$ , jejichž předpis nezávisí na  $\theta$  a které splňují  $P[L(X_1, \dots, X_n) \leq \theta \leq U(X_1, \dots, X_n)] \geq 1 - \alpha$  (Interval spolehlivosti s hladinou spolehlivosti  $1 - \alpha$ ) pro každé  $\theta$ , je-li  $\theta$  skutečnou hodnotou parametru.

Náhodné jsou  $L$  a  $U$ ! Když provádíme náhodné experimenty, Počet intervalů  $(L, U)$  pokrývajících  $\theta$  je v průměru  $100(1 - \alpha)\%$ . Naše snaha je získat  $|UL|$  co nejmenší.

Jak najít  $L$  a  $U$ ? Možné postupy:

1. Najdeme funkci  $H: (X_1, \dots, X_n, \theta)$ , jejíž rozdělení nezávisí na  $\theta$ . (nebo alespoň nezávisí asymptoticky). Obvykle pomůže Centrální limitní věta.

Příkladem je  $X_1, \dots, X_n$  s alternativním rozdělením závislém na  $p$ , odhadem může být  $\frac{\sum x_i - np}{\sqrt{np(1-p)}} \xrightarrow{d} N(0, 1)$  nezávislé na  $p$ .

2. Najdeme kvantily  $l(\alpha), u(\alpha)$  rozdělení  $H$  takové, že  $P[l(\alpha) \leq H \leq u(\alpha)] \geq 1 - \alpha$ . Je-li (asymptotické) rozdělení  $H$  normální  $N(0, 1)$ , pak použijeme kvantily  $l(\alpha) = q(\alpha/2) = \Phi^{-1}(\frac{\alpha}{2})$  a  $u(\alpha) = q_{1-\alpha/2} = \Phi^{-1}(1 - \frac{\alpha}{2})$ .

3. Osvobození parametru různými algebraickými úpravami dojdeme k nerovnosti  $l(\alpha) \leq H \leq u(\alpha)$  právě, když  $L(X_1, \dots, X_n, l, u) \leq \theta \leq U(X_1, \dots, X_n, l, u)$  je-li to možné.

Avšak někdy ještě musíme zapojit Cramér–Slutskij větu.

**Příklad.** Mějme  $\text{Alt}(p)$ , potom  $\frac{\sum X_i - np}{\sqrt{np(1-p)}} \in (q_{\alpha/2}, q_{1-\alpha/2})$  s pravděpodobností přibližně  $pa$ . Dále z kvantilů získáme  $q_{\alpha/2} \sqrt{np(1-p)} \leq \sum X_i - np \leq q_{1-\alpha/2} \sqrt{np(1-p)}$ , máme kvadratickou nerovnost.

Nebo můžeme použít Cramér–Slutskij větu a máme  $\bar{X}_n \xrightarrow{P} p \Rightarrow \bar{X}_n(1 - \bar{X}_n) \xrightarrow{P} p(1-p)$ . Z toho dostáváme, že  $\frac{\sum X_i - np}{\sqrt{n\bar{X}_n(1-\bar{X}_n)}} \xrightarrow{d} N(0, 1)$ . Potom  $q_{\alpha/2} \sqrt{n\bar{X}_n(1-\bar{X}_n)} \leq p \leq q_{1-\alpha/2} \sqrt{n\bar{X}_n(1-\bar{X}_n)}$ . Z toho již dostaneme  $L = \bar{X}_n + \frac{q_{\alpha/2}}{\sqrt{n}} \sqrt{n\bar{X}_n(1-\bar{X}_n)}$  a  $U = \bar{X}_n + \frac{q_{1-\alpha/2}}{\sqrt{n}} \sqrt{n\bar{X}_n(1-\bar{X}_n)}$ , potom  $P[L \leq p \leq U] \approx 1 - \alpha$ .

*Použití intervalového odhadu.* Rozhodnutí o hypotéze: Mějme  $H_0$  hypotézu, takovou, že  $H_0 : \theta = \theta_0$ . Dále mějme alternativu  $H_1 : \theta \neq \theta_0$ .

Intervalový odhad pro neznáme  $\theta$  se spolehlivostí  $1 - \alpha$ . Máme  $(L, U)$  takové, že  $P(L \leq \theta \leq U) = 1 - \alpha$ . Je naše  $\theta_0 \in (L, U)$ ? Pokud ano,  $H_0$  nezamítneme na hladině statistické významnosti  $\alpha$ . Pokud však ne, zamítneme ji.

Všimněme si, že se zvyšujícím se  $n$  se interval  $(L, U)$  zmenšuje. Je potřeba také vážit faktický význam!