

Pravděpodobnost a matematická statistika (NMSA202)

Petr Velička *

přednášející: doc. RNDr. Michal Pešta, Ph.D. †

LS 2024/25

*petrvel@matfyz.cz
†pesta@karlin.mff.cuni.cz

1 Náhodné jevy

Začneme nejdříve základními definicemi, bez nichž vůbec nemůžeme mluvit o pravděpodobnosti.

Definice 1.1. *Výběrovým prostorem* rozumíme množinu Ω všech možných výsledků nějakého experimentu. Prvky $\omega \in \Omega$ této množiny nazýváme *elementárními jevy*. Podmnožině $A \subset \Omega$ říkáme *(náhodný) jev*.

Pro ilustraci uvedeme následující motivační příklad, kde podrobně popíšeme souvislosti s právě zadefinovanými pojmy.

Příklad 1.2. Házíme dvakrát férovou minci. Naším výběrovým prostorem bude množina $\Omega = \{PP, PO, OP, OO\}$. Událost, že první hod je panna, je tedy $A = \{PP, PO\}$. V tomto zápisu písmeno P odpovídá tomu, že padla panna, kdežto písmeno O odpovídá orlu.

Dále uvažujme jevy H_1 – při prvním hodu padne panna, a H_2 – při druhém hodu padne panna. Nechť jsou všechny výsledky stejně pravděpodobné (jinými slovy, mince je férová), potom pravděpodobnost, že padne alespoň jedna panna (tj. nastane jev $H_1 \cup H_2$) je $\frac{3}{4}$.

Důkaz. Zřejmě z předchozího máme $H_1 = \{PP, PO\}$ a $H_2 = \{OP, PP\}$. Pravděpodobnost spočteme jako podíl velikosti $|H_1 \cup H_2| = 3$ a velikosti celého prostoru $|\Omega| = 4$. \square

Tato jednoduchá intuice však selže v případě nekonečné (nespočetné) množiny Ω , neboť jak již čtenář jistě ví z přednášky základů teorie míry, na nespočetné množině neexistuje “rozumný” způsob, jak měřit množiny. Musíme proto pracovat pouze s jistou třídou podmnožin Ω , které budeme říkat σ -algebra.

Definice 1.3. Nechť $\Omega \neq \emptyset$ je množina a $\mathcal{A} \subset 2^\Omega$ soubor jejích podmnožin. Této množině \mathcal{A} říkáme σ -algebra, jestliže jsou splněny následující podmínky:

- (i) $\emptyset \in \mathcal{A}$,
- (ii) Pokud $A \in \mathcal{A}$, pak $A^C := \Omega \setminus A \in \mathcal{A}$,
- (iii) Pokud $A_1, A_2, \dots \in \mathcal{A}$, pak $\bigcup_{i=1}^{\infty} A_i \in \mathcal{A}$.

Dvojici (Ω, \mathcal{A}) nazýváme *měřitelný prostor*.

Každé události $A \in \mathcal{A}$ přiřadíme číslo $\mathbb{P}(A)$, které nazýváme *pravděpodobnost* jevu A . Jelikož chceme, aby se zachovala intuice z předchozího příkladu, musíme tuto představu náležitým způsobem formalizovat.

Definice 1.4. Nechť (Ω, \mathcal{A}) je měřitelný prostor. Zobrazení $P : \mathcal{A} \rightarrow [0, 1]$ nazýváme *pravděpodobnostní mírou* (*pravděpodobností*), jestliže:

- (i) $P(\Omega) = 1$,
- (ii) Pro libovolné po dvou disjunktní měřitelné množiny $A_i \in \mathcal{A}$, $i \in \mathbb{N}$ platí $P(\bigcup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$.

Trojici (Ω, \mathcal{A}, P) nazýváme *pravděpodobnostní prostor*.

Přímo z této definice již můžeme odvodit pár základních vlastností pravděpodobnosti, se kterými dále budeme pracovat. Ve všech následujících tvrzeních pracujeme s pravděpodobnostním prostorem (Ω, \mathcal{A}, P) .

Pozorování 1.5 (Základní vlastnosti pravděpodobnostní míry). *Pro výše jmenovaný pravděpodobnostní prostor platí následující tvrzení:*

1. $P(\emptyset) = 0$,
2. Pro $A, B \in \mathcal{A}$ disjunktní platí $P(A \cup B) = P(A) + P(B)$.
3. Pro $A \in \mathcal{A}$ platí $P(A^C) = 1 - P(A)$,
4. Pro $A, B \in \mathcal{A}, A \subset B$ platí $P(A) \leq P(B)$.

Důkaz. 1. Uvažujme posloupnost $A_1 = \Omega, A_2 = A_3 = \dots = \emptyset$. Potom z vlastnosti (ii) z definice máme, že $P(\Omega) = P(\Omega \cup \emptyset \cup \emptyset \dots) = P(\Omega) + \sum_{n=2}^{\infty} P(\emptyset)$. Tedy $\sum_{n=2}^{\infty} P(\emptyset) = 0$, což může nastat pouze v případě $P(\emptyset) = 0$ (jde o součet nekonečně mnoha nezáporných čísel).

2. Nechť $A_1 = A, A_2 = B, A_i = \emptyset$ pro $i > 2$. Tvrzení plyne přímo z vlastnosti (ii) z definice pravděpodobnostní míry a již dokázané vlastnosti 1.
3. $1 = P(\Omega) = P(A \cup A^C) = P(A) + P(A^C)$. Tato rovnost platí, neboť množina je vždy disjunktní se svým komplementem.
4. $P(B) = P(A \cup B \setminus A) = P(A) + P(B \setminus A)$. Jelikož funkce P je nezáporná, snadno vidíme, že $P(B) \geq P(A)$.

□

Lemma 1.6 (Pravděpodobnost sjednocení). *Pro libovolné $A, B \in \mathcal{A}$ platí $P(A \cup B) = P(A) + P(B) - P(A \cap B)$.*

Důkaz. Rozepíšeme $A \cup B = (A \cap B^C) \cup (A \cap B) \cup (A^C \cap B)$. Tyto tři množiny jsou zřejmě po dvou disjunktní. Dále díky aditivitě pravděpodobnosti máme $P(A \cup B) = P(A \cap B^C) + P(A \cap B) + P(A^C \cap B) + P(A \cap B) - P(A \cap B) = P(A) + P(B) - P(A \cap B)$. □

Věta 1.7 (Spojitost pravděpodobnosti). *Budě $A_n \uparrow A$ nebo $A_n \downarrow A$ pro $A_n, A \in \mathcal{A}$. Potom platí $P(A_n) \rightarrow P(A)$.*

Důkaz. Nechť $A_n \uparrow A$. Potom z definice $A_1 \subset A_2 \dots$ a platí $A = \bigcup_{i=1}^{\infty} A_i$. Definujme posloupnost B_n : $B_1 = A_1, B_n = A_n \setminus A_{n-1}$. Potom B_i jsou po dvou disjunktní a platí $A_n = \bigcup_{i=1}^n B_i$. Zřejmě také platí $A \equiv \bigcup_{n=1}^{\infty} A_n = \bigcup_{n=1}^{\infty} B_n$. Pak $P(A_n) = P(\bigcup_{i=1}^n B_i) = \sum_{i=1}^n P(B_i)$. Z toho již můžeme odvodit $\lim_{n \rightarrow \infty} P(A_n) = \lim_{n \rightarrow \infty} \sum_{i=1}^n P(B_i) = \sum_{i=1}^{\infty} P(B_i) = P(\bigcup_{i=1}^{\infty} B_i) = P(A)$.

Případ klesající A_n se dokáže analogicky, stačí uvažovat $C_n = A_n^C$. □

konec 1. přednášky (17.2.2025)

Uvedeme si ještě jeden příklad ilustrující intuitivní chápání pravděpodobnosti a zavedeme první takzvané pravděpodobnostní rozdělení. Uvažujme případ, že prostor Ω je konečný. Nechť všechny výsledky jsou stejně pravděpodobné, pak platí

$$P(A) = \frac{|A|}{|\Omega|}.$$

V tomto případě mluvíme o *rovnoměrném rozdělení pravděpodobnosti*.

Příklad 1.8 (Hod dvěma kostkami). Výběrový prostor $\Omega = \{(i, j) : i, j \in \{1 \dots 6\}\}$ má 36 prvků. Jestliže všechny výsledky jsou stejně pravděpodobné, pak platí $P(A) = \frac{|A|}{36}$. Například, pravděpodobnost toho, že součet na kostkách je přesně 11, je $2/36$, protože pouze dva výsledky (5, 6) a (6, 5) odpovídají této události.

V praxi často chceme odlišit, zda pravděpodobnost výskytu jedné události nějakým způsobem závisí na výskytu jiné události. K tomu nám poslouží pojem nezávislosti jevů.

Definice 1.9. Dvě události $A, B \in \mathcal{A}$ jsou *nezávislé*, jestliže platí $P(A \cap B) = P(A)P(B)$. Obdobně, množina událostí $\{A_i : i \in I\}$ (kde indexová množina I je nejvýše spočetná) je nezávislá, jestliže platí

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

pro každou konečnou podmnožinu $J \subset I$.

Je důležité si uvědomit, že disjunktní události s kladnou pravděpodobností nejsou nezávislé (neboť součin jejich pravděpodobností není roven 0 – pravděpodobnost výskytu jejich prázdného průniku). Obecně se pracuje se dvěma typy nezávislosti – předpokládanou (plyne z podstaty zkoumané úlohy) a odvozenou (dokázaná pomocí jiných vlastností úlohy). Následující příklad ilustruje praktické použití právě zavedeného pojmu.

Příklad 1.10. Házíme férovou minci 10krát. Nechť A je událost “padla aspoň jedna panna”. Pak platí $P(A) = 1 - (1/2)^{10}$.

Důkaz. Nechť T_j je událost, že při j -té hodou padne orel. Můžeme psát $P(A) = 1 - P(A^C) = 1 - P(\text{samé orly}) = 1 - P(T_1 \cap \dots \cap T_{10})$. Dále díky nezávislosti (v tomto případě jde o nezávislost předpokládanou) jevů T_j máme $1 - P(T_1 \cap \dots \cap T_{10}) = 1 - P(T_1) \cdots P(T_{10}) = 1 - (1/2)^{10} \approx 0.999$. \square

Dalším silným nástrojem v teorii pravděpodobnosti je podmíněná pravděpodobnost, která nám poskytuje odpověď na otázku “Pokud vím, že nastala událost B , jaká je pravděpodobnost události A ?“.

Definice 1.11. Mějme jevy $A, B \in \mathcal{A}$. Pokud $P(B) > 0$, pak podmíněná pravděpodobnost A za podmínky B je definována vztahem

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

Poznamenejme si několik základních vlastností podmíněné pravděpodobnosti, jejichž důkaz snadno plyne z příslušných definic.

Pozorování 1.12 (Vlastnosti podmíněné pravděpodobnosti).

- (i) Pro pevné $B \in \mathcal{A}, P(B) > 0$ je $P(\cdot|B)$ pravděpodobnostní míra.
- (ii) Obecně platí $P(A|B) \neq P(B|A)$, platí totiž $P(A|B) = P(B|A) \frac{P(A)}{P(B)}$ (pokud obě strany rovnosti dávají smysl).
- (iii) Události A a B jsou nezávislé právě tehdy, když $P(A|B) = P(A)$ (předpokládáme nenulovost $P(B)$).
- (iv) $P(A \cap B) = P(A|B)P(B) = P(B|A)P(A)$ v případě, že $P(A)P(B) > 0$.

Důkaz. Vlastnosti (iii) a (iv) plynou přímo z definice vynásobením vhodnou konstantou.

Vlastnost (ii) se dokáže následujícím protipříkladem, uvažujme hod dvěma férrovými mincemi. Nechť H_1 je událost “padla aspoň jedna panna” a H_2 událost “padly dvě panny”. Potom $P(H_1|H_2) = 1$ ale $P(H_2|H_1) = \frac{1}{3}$. Důkaz obecného vztahu je ponechán čtenáři jako snadné (ale užitečné) cvičení.

Nakonec, vlastnost (i) je důsledkem toho, že pro libovolnou množinu $A \in \mathcal{A}$ je $A \cap B$ měřitelná, a navíc pro libovolný systém po dvou disjunktních množin $A_i, i \in \mathbb{N}$ platí $P(\bigcup_{i=1}^{\infty} A_i|B) = \frac{1}{P(B)} P((\bigcup_{i=1}^{\infty} A_i) \cap B) = \frac{1}{P(B)} P(\bigcup_{i=1}^{\infty} (A_i \cap B)) = \frac{1}{P(B)} \sum_{i=1}^{\infty} P(A_i \cap B) = \sum_{i=1}^{\infty} P(A_i|B)$. \square

Použití podmíněné pravděpodobnosti v praxi však někdy může vést k neintuitivním výsledkům, které ilustruje následující příklad.

Příklad 1.13. Uvažujme nemoc D a test, který má dva možné výsledky. Pravděpodobnosti výsledků tohoto testu jsou uvedeny v následující tabulce. Zde sloupce odpovídají přítomnosti/absenci nemoci a řádky výsledkům testu.

	D	D^C
+	0.009	0.099
-	0.001	0.891

Z definice spočteme následující podmíněné pravděpodobnosti:

$$P(+|D) = \frac{P(+ \cap D)}{P(D)} = \frac{0.009}{0.009 + 0.001} = 0.9.$$

$$P(-|D^C) = \frac{P(- \cap D^C)}{P(D^C)} = \frac{0.891}{0.891 + 0.099} \approx 0.9.$$

Vychází nám, že test je docela přesný, neboť nemocní lidé mají test v 90% případů pozitivní, stejně tak zdraví lidé jsou v 90% případů negativní.

Dále předpokládejme, že pacient šel na test a získal pozitivní výsledek. Spočteme, s jakou pravděpodobností je opravdu nakažený.

$$P(D|+) = \frac{P(D \cap +)}{P(+)} = \frac{0.009}{0.009 + 0.099} \approx 0.08.$$

Vyšlo nám, že na první pohled zdánlivě precizní test ve skutečnosti má méně než 10% úspěšnost. Jedním z důvodů této diskrepance může být například velký nepoměr zdravých lidí vůči nakaženým (pouze jedno procento) ve zdrojových datech, což je jev který se obecně vyskytuje u většiny nemocí. V praxi se proto často pracuje s domněnkami – například testujeme jen pacienty, kteří vykazují nějaké symptomy apod.

Na závěr uvedeme dvě velmi užitečné věty, které se často používají v nejrůznějších úlohách a týkají se podmíněné pravděpodobnosti. Zformulujeme je pro spočetné rozklady, ale obdobná tvrzení platí i pro konečné rozklady s velmi podobným důkazem.

Věta 1.14 (Zákon úplné pravděpodobnosti). *Nechť A_1, A_2, \dots je spočetný disjunktní rozklad Ω takový, že $P(A_i) > 0$ pro každé $i \in \mathbb{N}$. Potom pro libovolnou událost $B \in \mathcal{A}$ platí:*

$$P(B) = \sum_{i=1}^{\infty} P(B|A_i)P(A_i).$$

Důkaz. Definujme posloupnost množin $C_i = B \cap A_i$ pro $i \in \mathbb{N}$. Zjevně $\{C_i, i \in \mathbb{N}\}$ je disjunktní pokrytí B . Potom $P(B) = \sum_{i=1}^{\infty} P(C_i) = \sum_{i=1}^{\infty} P(B \cap A_i) = \sum_{i=1}^{\infty} P(B|A_i)P(A_i)$. \square

Věta 1.15 (Bayes). *Nechť A_1, A_2, \dots je spočetný disjunktní rozklad Ω takový, že $P(A_i) > 0$ pro každé $i \in \mathbb{N}$. Mějme událost $B \in \mathcal{A}$ s nenulovou pravděpodobností. Potom platí:*

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^{\infty} P(B|A_j)P(A_j)}.$$

Důkaz. Přímým výpočtem dostaváme

$$P(A_i|B) = \frac{P(A_i \cap B)}{P(B)} = \frac{P(B|A_i)P(A_i)}{P(B)} = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^{\infty} P(B|A_j)P(A_j)},$$

kde poslední rovnost získáme aplikací *Věty 1.14*. \square

Použití Bayesovy věty si ukážeme na následujícím příkladu.

Příklad 1.16. Uvažujme e-mailovou schránku. Máme tři kategorie e-mailů: A_1 – spam, A_2 – nízká priorita, A_3 – vysoká priorita. Na základě předchozích zkušeností víme, že $P(A_1) = 0.7$, $P(A_2) = 0.2$, $P(A_3) = 0.1$. Nechť B je událost, že daný e-mail obsahuje slovo “zdarma”. Platí $P(B|A_1) = 0.9$, $P(B|A_2) =$

0.01 , $P(B|A_3) = 0.01^1$. Jaká je pravděpodobnost, že příchozí e-mail obsahující slovo “zdarma” je spam?

Přímým výpočtem z Bayesovy věty získáme

$$P(A_1|B) = \frac{0.9 \cdot 0.7}{0.9 \cdot 0.7 + 0.01 \cdot 0.2 + 0.01 \cdot 0.1} = 0.995.$$

Tedy pravděpodobnost, že tento e-mail je spam je přes 99%!

Věta 1.17 (O postupném podmiňování). *Nechť $\{A_i\}_{i=1}^n$ jsou náhodné jevy takové, že $P(\bigcap_{i=1}^n) > 0$. Pak platí*

$$P\left(\bigcap_{i=1}^n A_i\right) = P(A_n \mid \bigcap_{i=1}^{n-1} A_i) \cdot P(A_2 \mid A_1) \cdot P(A_1).$$

Důkaz. Dokazujeme indukcí podle počtu náhodných jevů. Z definice podmíněné pravděpodobnosti víme, že $P(A_2 \cap A_1) = P(A_2|A_1)P(A_1)$. Dále

$$P\left(\bigcap_{i=1}^n\right) = P\left(A_n \cap \left(\bigcap_{i=1}^{n-1} A_i\right)\right) = P\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right) P\left(\bigcap_{i=1}^{n-1}\right),$$

čímž je důkaz ukončen. \square

¹Tyto hodnoty se nutně nemusí sečíst na 1

2 Náhodné veličiny

V této kapitole se budeme věnovat náhodným veličinám, což bude formalizovat (a zobecňovat) jakýsi intuitivní chápání toho, že nějaká proměnná nabývá různých hodnot s určitými pravděpodobnostmi. Začneme ústřední definicí celé statistiky – náhodnou veličinou.

Definice 2.1. Nechť (Ω, \mathcal{A}) je měřitelný prostor. *Náhodná veličina* je měřitelné zobrazení, které přiřazuje každému výsledku ω reálné číslo $X(\omega)$. Jinými slovy, $\{\omega \in \Omega : X(\omega) \leq x\} \in \mathcal{A} \forall x \in \mathbb{R}$.

konec 2. přednášky (18.2.2025)

Úmluva 2.2. Zavedeme značení $[X \in B] = \{\omega : X(\omega) \in B\}$, $[X \leq a] = \{\omega, X(\omega) \leq a\}$. Platí tedy $[X \in B], [X \leq a] \in \mathcal{A}$ pro všechna $B \in \mathcal{B}, a \in \mathbb{R}$. Jde o náhodné jevy a jsou tedy dobře definované jejich pravděpodobnosti $P[X \in B], P[X \leq a]$.

Příklad 2.3. Házíme minci desetkrát. Nechť $X(\omega)$ je počet orlů v posloupnosti ω . Jestliže $\omega = OOPPOOOPPP$ (kde O je orel a P je panna), platí $X(\omega) = 6$.

V předchozí kapitole jsme mluvili o pravděpodobnostním rozdělení, je na čase tento pojem formálně zadefinovat.

Definice 2.4. *Rozdělením náhodné veličiny $X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$* nazýváme indukovanou pravděpodobnostní míru P_X na $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ definovanou jako

$$P_X(B) := P[\{\omega \in \Omega : X(\omega) \in B\}], B \in \mathcal{B}(\mathbb{R}).$$

Máme tedy jakýsi obraz míry P v zobrazení P_X čímž se (Ω, \mathcal{A}, P) zobrazí na pravděpodobnostní prostor $(\mathbb{R}, \mathcal{B}(\mathbb{R}), P_X)$. V opačném směru můžeme použít takzvané kanonické vnoření do prostoru $(\mathbb{R}, \mathcal{B}, P_X)$, kde naší zvolenou měřitelnou funkcí bude identita, tedy není potřeba se bát, že by příslušný prostor nemusel existovat. Následující věta říká, že nezáleží ve kterém z těchto dvou prostorů integrujeme libovolnou funkci.

Věta 2.5 (O přenosu integrace). *Budě g měřitelná funkce na měřitelném prostoru $(\mathbb{M}, \mathcal{M})$ a $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{M}, \mathcal{M})$. Nechť P_X je míra na \mathcal{M} indukovaná zobrazením X , tedy $P_X(M) = P[X^{-1}(M)]$ pro $M \in \mathcal{M}$. Potom, je-li aspoň jedna strana definována, platí*

$$\int_{\Omega} g[X(\omega)] dP(\omega) = \int_{\mathbb{M}} g(x) dP_X(x).$$

Důkaz. Důkaz této věty je poměrně technický, hlavní ideou je “klasický” postup z teorie míry postupným důkazem nejdříve pro charakteristickou funkci, poté pro jednoduchou měřitelnou (nabývající jen konečně mnoha hodnot), pak pro nezápornou měřitelnou a na závěr pro obecnou měřitelnou funkci.

Nechť $g = \chi_B, B \in \mathcal{M}$. Tedy $g(X(\omega)) = 1$ pro $X(\omega) \in B$ (a všude jinde nulová), tedy pro $\omega \in X^{-1}(B)$. Potom máme

$$\int_{\Omega} g(X(\omega)) dP(\omega) = \int_{X^{-1}(B)} dP(\omega) = P[X^{-1}(B)].$$

Pro pravou stranu máme

$$\int_{\mathbb{M}} g(x) dP_X(x) = \int_B dP_X(x) = P_X(B) = P[X^{-1}(B)].$$

Dále nechť g je jednoduchá měřitelná, tedy $g(\cdot) = \sum_{k=1}^n c_k \chi_{B_k}(\cdot)$ pro $n \in \mathbb{N}$, $c_k \in \mathbb{R}$ a $B_k \in \mathcal{M}$ pro všechna k . Z linearity integrálu plyne (vytkneme sumu) $\int_{\Omega} g(X(\omega)) dP(\omega) = \int_{X^{-1}(B)} dP(\omega) = P[X^{-1}(B)]$.

Je-li g nezáporná měřitelná, potom existuje posloupnost g_n jednoduchých měřitelných funkcí takových, že $g_n \nearrow g$. Potom dle Léviho věty o monotonní konvergenci máme

$$\begin{aligned} \int_{\Omega} g[X(\omega)] dP(\omega) &= \lim_{n \rightarrow \infty} \int_{\Omega} g_n[X(\omega)] dP(\omega) \\ &= \lim_{n \rightarrow \infty} \int_{\mathbb{M}} g_n(x) dP_X(x) = \int_{\mathbb{M}} g(x) dP_X(x), \end{aligned}$$

kde třetí rovnost plyne z již dokázанé části pro jednoduché měřitelné funkce.

Nakonec, pro g měřitelnou existuje rozklad $g = g^+ - g^-$ takový, že g^+, g^- jsou nezáporné měřitelné, tedy požadované tvrzení plyne z části pro nezáporné měřitelné funkce. \square

Na závěr poznamenejme, že se nám budou obzvlášt hodit volby $(\mathbb{M}, \mathcal{M}) = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ pro $n \geq 1$.

Připomeňme si, že jsou-li μ, ν dvě σ -konečné míry na $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ a je-li $\nu \ll \mu$ (tedy $\mu(B) = 0$ implikuje $\nu(B) = 0$), potom z Radonovy-Nikodymovy věty plyne existence nezáporné měřitelné funkce f takové, že $\nu(B) = \int_{\mathbb{R}} f d\mu$ pro všechna $B \in \mathcal{B}$. Této funkci f říkáme Radonova-Nikodymova derivace a píšeme $f = \frac{d\nu}{d\mu}$. Taková funkce f je navíc určena jednoznačně až na množinu μ -míry 0.

Využijeme těchto poznatků tak, že zvolíme vhodnou referenční míru na \mathbb{R} a rozdělení P_X pak bude popsáno právě zavedenou Radonovou-Nikodymovou derivací. Vhodné referenční míry jsou např.

- Lebesgueova míra λ ,
- Čítací míra na spočetné podmnožině \mathbb{R} , platí $\mu_S(B) = |B \cap S|$ kde S je nejvýše spočetná podmnožina \mathbb{R} .

Definice 2.6. Buď X náhodná veličina a P_X její rozdělení. Nechť P_X je absolutně spojité vůči μ , kde μ je σ -konečná míra na \mathbb{R} . Pak funkci f_X splňující $P_X(B) = \int_B f_X d\mu$ pro všechny $B \in \mathbb{B}$ nazveme *husotou* rozdělení náhodné veličiny X vůči míře μ .

Je třeba si dát pozor na to, aby zvolená referenční míra opravdu byla absolutně spojitá, například při hodu kostkou má výsledek 1 nenulovou pravděpodobnost, ale $\lambda(\{1\}) = 0$.

Věta 2.7. *Bud X náhodná veličina a P_X její rozdělení. Je-li f_X hustota (rozdělení) vůči σ -konečné míře μ , pak*

$$P[X \in B] = \int_B f_X d\mu.$$

Důkaz. Jde o přímý důsledek Radonovy-Nikodymovy věty a vztahu mezi P_X a P . \square

Další funkci, která plně charakterizuje rozdělení náhodné veličiny je tzv. distribuční funkce.

Definice 2.8. Bud X náhodná veličina na (Ω, \mathcal{A}, P) a P_X její rozdělení. Distribuční funkce F_x náhodné veličiny X je definována vztahem

$$F_X(a) := P((-\infty, a]) = P[X \leq a].$$

Uvedeme si několik užitečných vlastností distribučních funkcí:

Důsledek 2.9 (Základní vlastnosti distribučních funkcí).

- (i) Distribuční funkce jednoznačně určuje rozdělení (jinými slovy, $F_X = F_Y$ implikuje $P_X = P_Y$).
- (ii) Různé náhodné veličiny mohou mít stejné distribuční funkce, tedy stejné rozdělení.

konec 3. přednášky (24.2.2025)

Příklad 2.10. Hodíme dvěma kostkami, označme Y počet sudých čísel na těchto dvou kostkách. Potom $Y \in \{0, 1, 2\}$. Z definice $F_Y(a) = P[Y \leq a]$, tedy

$$F_Y(a) = \begin{cases} 0, & a < 0, \\ \frac{1}{4}, & 0 \leq a < 1, \\ \frac{3}{4}, & 1 \leq a < 2, \\ 1, & a \geq 2. \end{cases}$$

Dále, z toho, že $P_Y(0) = \frac{1}{4} > 0$, plyne, že míra P_Y není absolutně spojitá vůči Lebesgueově míře λ , tedy musíme uvažovat čítací míru $\mu_{\mathbb{Z}}$ na množině celých čísel. Potom hustota f_Y má následující tvar:

$$f_Y(a) = \begin{cases} \frac{1}{4}, & a = 0, \\ \frac{1}{2}, & a = 1, \\ \frac{1}{4}, & a = 2, \\ 0, & \text{jinak.} \end{cases}$$

Vidíme, že hustota odpovídá skokům distribuční funkce v daném bodě. V následující větě uvedeme charakterizaci distribučních funkcí.

Věta 2.11 (Charakterizace distribučních funkcí). *Bud X náhodná veličina a F_X její distribuční funkce. Pak*

- (i) F_X je neklesající;
- (ii) $\lim_{a \rightarrow -\infty} F_X(a) = 0$, $\lim_{a \rightarrow +\infty} F_X(a) = 1$;
- (iii) F_X je zprava spojitá.

Navíc, každá funkce F splňující body (i)-(iii) z této věty je distribuční funkcí nějaké náhodné veličiny.

Důkaz. Dokážeme pouze implikaci o vlastnostech distribuční funkce, opačná implikace (existuje rozdělení) vyžaduje pokročilý matematický aparát z analýzy a teorie míry, který prozatím postrádáme.

- (i) $F_X(a) = P[X \leq a]$. Bez újmy na obecnosti nechť $b > a$. Potom $F_X(b) = P[X \leq b] = P([X \leq a] \cup [a < X \leq b]) = P[X \leq a] + P[a < X \leq b]$ z aditivity míry, druhý sčítanec je nezáporný, tedy dostáváme požadované tvrzení.
- (ii) Platí $\lim_{a \rightarrow -\infty} = \lim_{n \rightarrow \infty} F_X(-n) = \lim_{n \rightarrow \infty} P[X \in (-\infty, -n)] =: \lim_{n \rightarrow \infty} P[X \in A_n] = 0$. Poslední rovnost platí ze spojitosti míry (Věta 1.7), neboť platí $A_n \searrow \emptyset$. Obdobně se ukáže tvrzení pro $a \rightarrow +\infty$ (cvičení).
- (iii) Stačí uvažovat posloupnost $a_n = a + \frac{1}{n}$ pro $n \in \mathbb{N}$. Požadované tvrzení opět plyne z věty o spojitosti míry.

□

Pro každou funkci F splňující vlastnosti z předchozí věty existuje míra μ_F na $(\mathbb{R}, \mathcal{B})$ určená vztahem $\mu_F((-\infty, a]) = F(a)$ pro všechna a . Tato míra je konečná a platí $\mu_F((a, b]) = F(b) - F(a)$.

Definice 2.12 (Rozklad pravděpodobnostního rozdělení). Každou pravděpodobnostní míru P_X můžeme rozdělit na tři složky $P_X = P_{X_{as}} + P_{X_{ds}} + P_{X_{sg}}$, kde $P_{X_{as}}$ je absolutně spojitá vůči Lebesgueově míře λ , $P_{X_{ds}}$ (diskrétní spojitá) je absolutně spojitá vůči čítací míře μ na nějaké spočetné podmnožině \mathbb{R} a nакonec $P_{X_{sg}}$ (singulární) není absolutně spojitá vůči λ ani ji nelze napsat jako spočetnou kombinaci Diracových měr δ_x .

Příkladem singulární distribuční funkce je například integrál takzvaného Cantorova diskontinua. Obecně taková rozdělení nemají "hezké" vlastnosti, proto s nimi již nebudeš pracovat.

Definice 2.13. Náhodnou veličinu X nazveme *diskrétní*, jestliže existují $\emptyset \neq I \subset \mathbb{N}$, $\{x_i\}_{i \in I}$ a $\{p_i \in (0, 1]\}_{i \in I}$ takové že $P[X \in B] = \sum_{i, x_i \in B} p_i$ pro všechny borelovské B .

Platí $P[X = x_i] = p_i$ a $\sum_{i \in I} p_i = 1$. Rozdelením takové veličiny je funkce $P_X = \sum_{i \in I} p_i \delta_{x_i}$, kde δ_u je Diracova míra v bodě u . Toto rozdelení je absolutně spojité vůči čítací míře na $S = \{x_i\}_{i \in I} \subset \mathbb{R}$. Potom funkce $f_X(u) := \begin{cases} p_i, & u = x_i, \\ 0, & \text{jinak} \end{cases}$ je hustotou (občas také pravděpodobnostní funkcí) zkoumaného rozdelení.

Definice 2.14. Náhodná veličina X se nazývá (*absolutně*) *spojitá*, pokud její rozdelení P_X je absolutně spojité vůči Lebesgueově míře λ .

Pro spojitou náhodnou veličinu X vždy existuje hustota f_X (nezáporná a jednoznačná až na množinu λ -míry 0) splňující $P[X \in B] = \int_B f_X(t)dt$ a speciálně $F_X(a) = \int_{-\infty}^a f_X(t)dt$ pro všechna $a \in \mathbb{R}$. Taková F_X má derivaci ve skoro všech bodech a platí $F'_X(a) = f_X(a)$ pro s.v. a . Analogicky pro diskrétní náhodnou veličinu Y je hustota funkčí, která nabývá v bodě a hodnoty distribuční funkce v daném bodě.

Ne každá veličina, se kterou se běžně setkáme je ryze spojitá nebo ryze diskrétní. Příkladem veličiny, která má obě složky nenulové, je například úhrn denních srážek, s nenulovou pravděpodobností nenaprší vůbec, ale když už začne pršet, úhrn srážek je spojitá náhodná veličina.

Lemma 2.15. Nechť F_X je distribuční funkce náhodné veličiny X . Pak pro $a < b$ platí

- (i) $P[a < X \leq b] = P[X \in (a, b)] = F_X(b) - F_X(a),$
- (ii) $P[X > a] = 1 - F_X(a),$
- (iii) $P[X = a] = F_X(a) - F_X(a^-)$, kde $F_X(a^-)$ je limita zleva $\lim_{h \rightarrow 0^+} F_X(a-h)$ a odtud $P[a \leq X \leq b] = F_X(b) - F_X(a^-)$.
- (iv) pro spojitu náhodnou veličinu platí $P[a \leq X \leq b] = P[a \leq X < b] = P[a < X \leq b] = P[a < X < b] = F_X(b) - F_X(a)$.

Důkaz. Důkaz je jednoduchý, plyne z příslušných definic. Uvedeme např. důkaz pro bod (iii).

$$P[X = a] = \lim_{h \rightarrow 0^+} P[a-h < X \leq a] = F_X(a) - \lim_{h \rightarrow 0^+} F_X(a-h). \quad \square$$

konec 4. přednášky (25.2.2025)

Dalším užitečným pojmem je funkce inverzní k distribuční funkci, které běžně říkáme kvantil.

Definice 2.16. Nechť X je náhodná veličina s distribuční funkcí F . Inverzní distribuční funkce neboli *kvantilová funkce* je definována jako

$$F^{-1}(q) = \inf \{x : F(x) > q\}$$

pro $q \in (0, 1)$. Hodnoty F^{-1} ve speciálních bodech mají své vlastní názvy:

- $F^{-1}(\frac{1}{4})$ je *první kvartil*,

- $F^{-1}(\frac{1}{2})$ je medián,
- $F^{-1}(\frac{3}{4})$ je třetí kvartil.

Je-li F ryze rostoucí a spojitá, je $F^{-1}(q)$ to jediné $x \in \mathbb{R}$ takové, že $F(x) = q$, jinými slovy, F je bijekce z \mathbb{R} do $(0, 1)$. Tako definovaná kvantilová funkce je neklesající a zprava spojitá. Dále z F^{-1} můžeme jednoznačně určit F , tedy také charakterizuje rozdělení P_X . Nakonec, o dvou náhodných veličinách X a Y říkáme, že jsou stejně rozdělené, zapisujeme $X \stackrel{d}{=} Y$, právě tehdy, když $F_X(x) = F_Y(x)$ pro všechna x . To však neznamená, že $X = Y$.

Ukážeme si několik užitečných příkladů rozdělení (diskrétních a později i spojitéch). Tato rozdělení se používají v praxi při modelování jednoduchých systémů, ale u komplikovanějších modelů se s těmito rozděleními bohužel nevystačíme.

2.1 Diskrétní náhodné veličiny

Definice 2.17 (Bodové rozdělení). Náhodná veličina X má *bodové rozdělení* v bodě a právě tehdy, když $P[X = x] = \chi_{\{x=a\}}$, $x \in \mathbb{R}$. Zapisujeme $X \sim \delta_a$. Potom platí $F_X(x) = \chi_{\{x \geq a\}}$.

Definice 2.18 (Diskrétní rovnoměrné rozdělení). Náhodná veličina X má *diskrétní rovnoměrné rozdělení* na $\{1, \dots, k\}$ právě tehdy, když

$$f_X(x) = \begin{cases} 1/k, & x = 1, \dots, k; \\ 0, & \text{jinak.} \end{cases}$$

Definice 2.19 (Bernoulliho rozdělení). Náhodná veličina X má *Bernoulliho rozdělení* s parametrem $p \in (0, 1)$ právě tehdy, když $f_X(x) = p^x(1-p)^{1-x}$ pro $x \in \{0, 1\}$. Zapisujeme $X \sim Alt(p)$ nebo $X \sim Be(p)$. Tímto rozdělením modelujeme jevy, u kterých jsou pouze dva možné výsledky (úspěch/neúspěch, hod mincí).

Definice 2.20 (Binomické rozdělení). Náhodná veličina X má *binomické rozdělení* s parametry $n \in \mathbb{N}$ a $p \in (0, 1)$ právě tehdy, když

$$f_X(x) = \binom{n}{x} p^x (1-p)^{n-x} \chi_{\{x \in \{0, \dots, n\}\}}.$$

Zapisujeme $X \sim Bi(n, p)$. Používáme toto v případě sčítaně nezávislých² veličin s Bernoulliho rozdělením (počet úspěchů mezi n pokusy).

Definice 2.21 (Geometrické rozdělení). Náhodná veličina X má *geometrické rozdělení* s parametrem $p \in (0, 1)$ (zapisujeme $X \sim Geo(p)$) právě tehdy, když

$$f_X(x) = p(1-p)^x$$

pro $x \in \mathbb{N}_0$. Taková náhodná veličina vyjadřuje počet neúspěchů před prvním úspěchem v posloupnosti nezávislých pokusů.

²Přesná definice nezávislých veličin bude uvedena později.

Definice 2.22 (Negativně binomické rozdělení). Náhodná veličina X má *negativně binomické rozdělení* s parametry $n \in \mathbb{N}$ a $p \in (0, 1)$ (píšeme $X \sim NB(n, p)$), jestliže platí

$$f_X(x) = \binom{n+x-1}{n-1} p^n (1-p)^x$$

pro $x \in \mathbb{N}_0$. Rozdělení vyjadřuje počet neúspěchů před n -tým úspěchem v posloupnosti nezávislých pokusů. Specifický případ $NB(1, p) = Geo(p)$.

Definice 2.23 (Poissonovo rozdělení). Náhodná veličina X má *Poissonovo rozdělení* s parametrem $\lambda > 0$ (zapisujeme $X \sim Po(\lambda)$) právě tehdy, když

$$f_X(x) = e^{-\lambda} \frac{\lambda^x}{x!}$$

pro $x \in \mathbb{N}_0$. Jestliže $X \sim Po(\lambda_X)$ a $Y \sim Po(\lambda_Y)$ jsou nezávislé, potom $X + Y \sim Po(\lambda_X + \lambda_Y)$. Jestliže $n \rightarrow \infty$ a $np \rightarrow \lambda < \infty$, potom $Bi(n, p)$ konverguje k $Po(\lambda)$.

2.2 Absolutně spojité náhodné veličiny

Definice 2.24 (Spojité rovnoměrné rozdělení). Náhodná veličina X má *rovnoměrné rozdělení* na intervalu $[a, b]$ právě tehdy, když $f_X(x) = (b-a)^{-1} \chi_{\{x \in [a, b]\}}$. Zapisujeme $X \sim U(a, b)$ (uniform) nebo $X \sim R(a, b)$ (rovnoměrné).

Definice 2.25 (Normální rozdělení). Náhodná veličina X má *normální (Gaussovo) rozdělení* s parametry $\mu \in \mathbb{R}$ a $\sigma^2 > 0$ (zapisujeme $X \sim N(\mu, \sigma^2)$) právě tehdy, když

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

pro $x \in \mathbb{R}$.

Toto rozdělení je enormě důležité, uvedeme si proto několik jeho vlastností. Nejprve, máme-li $X \sim N(\mu, \sigma^2)$, potom $Z := (X - \mu)/\sigma \sim N(0, 1)$. Tomuto rozdělení říkáme *standardní normální rozdělení*. Dále, máme-li dvě nezávislé normálně rozdělené veličiny $X \sim N(\mu_X, \sigma_X^2)$, $Y \sim N(\mu_Y, \sigma_Y^2)$, potom $X + Y \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$.

Distribuční funkce $N(0, 1)$ nejde vyjádřit analyticky, máme jen $\Phi(x) := \int_{-\infty}^x \phi(t) dt$, kde $\phi(x) := \frac{1}{\sqrt{2\pi}} \exp -x^2/2$ je hustota standardního normálního rozdělení. Její hodnoty proto vyhledáváme v tabulkách, případně počítáme numericky.

Příklad 2.26. Předpokládejme, že $X \sim N(3, 5)$. Spočteme $P[X \geq 1]$. Dále spočtěte $q = F_X^{-1}(0.2)$.

Důkaz. Počítáme přímo

$$P[X \geq 1] = 1 - P[X \leq 1] = 1 - P[Z \leq \frac{1-3}{\sqrt{5}}] \approx 1 - \Phi(-0.8944) = 0.81.$$

Dále z tabulek víme, že $\Phi(-0.8416) = 0.2$, potom

$$0.2 = P[X \leq q] = P[Z \leq \frac{q-\mu}{\sigma}] = \Phi[\frac{q-\mu}{\sigma}],$$

$$\text{proto } -0.8416 = \frac{q-\mu}{\sigma} = \frac{q-3}{\sqrt{5}} \text{ a tedy } q = 3 - 0.8416\sqrt{5} \approx 1.1181. \quad \square$$

Definice 2.27 (Exponenciální rozdělení). Náhodná veličina X má *exponenciální rozdělení* s parametrem $\lambda > 0$ (zapisujeme $X \sim Exp(\lambda)$) právě tehdy, když

$$f_X(x) = \lambda e^{-\lambda x} \chi_{\{x>0\}}.$$

Definice 2.28 (Gamma rozdělení). Náhodná veličina X má *Gamma rozdělení* s parametry $a, p > 0$ právě tehdy, když

$$f_X(x) = \frac{a^p}{\Gamma(p)} x^{p-1} e^{-ax} \chi_{\{x>0\}},$$

kde $\Gamma(p) = \int_0^\infty t^{p-1} e^{-t} dt$ je gamma funkce (spojité rozšíření faktoriálu). Zapijeme $X \sim Gamma(a, p)$ nebo $X \sim \Gamma(a, p)$. Exponenciální rozdělení $Exp(a)$ je speciálním případem Gamma rozdělení s parametrem $p = 1$.

Opět máme součtový vzorec pro nezávislé veličiny $X \sim \Gamma(a, p_X), Y \sim \Gamma(a, p_Y)$, platí totiž $X + Y \sim \Gamma(a, p_X + p_Y)$.

Definice 2.29 (Beta rozdělení). Náhodná veličina X má *Beta rozdělení* s parametry $\alpha, \beta > 0$ právě tehdy, když

$$f_X(x) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1} \chi_{\{x \in (0,1)\}}.$$

Zapisujeme $X \sim Beta(\alpha, \beta)$ nebo $X \sim B(\alpha, \beta)$. Všimněme si, že na rozdíl od předchozích rozdělení jde o rozdělení na kompaktu.

konec 5. přednášky (3.3.2025)

Definice 2.30 (χ^2 -rozdělení). Náhodná veličina X má χ^2 -rozdělení s p stupni volnosti (zapisujeme $X \sim \chi_p^2$) právě tehdy, když

$$f_X(x) = \frac{1}{\Gamma(p/2)2^{(p/2)}} x^{p/2-1} e^{-x/2} \chi_{\{x>0\}}.$$

Máme-li soubor nezávislých náhodných veličin $X_1, \dots, X_p \sim N(0, 1)$, potom součet jejich druhých mocnin odpovídá χ^2 -rozdělení, $\sum_{i=1}^p X_i^2 \sim \chi_p^2$.

Definice 2.31 (Studentovo t -rozdělení). Náhodná veličina X má Studentovo t -rozdělení s ν stupni volnosti (zapisujeme $X \sim t_\nu$) právě tehdy, když

$$f_X(x) = \frac{\Gamma((\nu+1)/2)}{\Gamma(\nu/2)\sqrt{\pi\nu}} \frac{1}{(1+x^2/\nu)^{(\nu+1)/2}}.$$

Definice 2.32 (Cauchyho rozdělení). Cauchyovo rozdělení je speciální případ t -rozdělení, když $\nu = 1$. Potom platí

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

K zajímavým vlastnostem Cauchyova rozdělení patří například to, že nemá střední hodnotu (bude upřesněno později).

Přejdeme dále k vícerozměrným náhodným veličinám, jedním z jejich využití je například možnost formální definice pojmu nezávislosti několika náhodných veličin.

Definice 2.33. Nechť (Ω, \mathcal{A}) je měřitelný prostor. *Náhodný vektor* je měřitelné zobrazení, které každému výsledku ω přiřadí reálný d -rozměrný vektor $\vec{X}(\omega)$. To znamená, že

$$\vec{X} : \Omega \rightarrow \mathbb{R}^d \wedge \{\omega \in \Omega : \vec{X}(\omega) \leq \vec{x}\} \in \mathcal{A} \forall \vec{x} \in \mathbb{R}^d.$$

Definice 2.34. *Rozdělením náhodného vektoru* $\vec{X} : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ nazveme indukovanou pravděpodobnostní míru $P_{\vec{X}}$ na $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ definovanou jako

$$P_{\vec{X}}(B) := P[\{\omega \in \Omega : \vec{X}(\omega) \in B\}]$$

pro všechny $B \in \mathcal{B}(\mathbb{R}^d)$.

Již na první pohled je zřejmá analogie s jednorozměrnými náhodnými veličinami v tom, že $P_{\vec{X}}$ je obraz míry P v zobrazení \vec{X} , kde se původní pravděpodobnostní prostor zobrazí na $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d), P_{\vec{X}})$. Platí, že pokud máme náhodný vektor $\vec{X} = [X_1, \dots, X_d]^T$, potom X_i je náhodná veličina pro všechna $i \in \{1, \dots, d\}$ (důsledek definice, avšak platí i opačná implikace).

Definice 2.35. Nechť (Ω, \mathcal{A}, P) je pravděpodobnostní prostor. *Sdružená distribuční funkce* náhodného vektoru \vec{X} je funkce $F_{\vec{X}} : \mathbb{R}^d \rightarrow [0, 1]$ definovaná jako

$$F_{\vec{X}}(\vec{x}) = P(\vec{X} \leq \vec{x}) = P\left(\bigcup_{l=1}^d \{X_l \leq x_l\}\right)$$

pro všechna $\vec{x} = [x_1, \dots, x_d]^T \in \mathbb{R}^d$.

Analogicky s náhodnými veličinami si zformulujeme tvrzení o základních vlastnostech sdružených distribučních funkcí.

Věta 2.36 (Vlastnosti sdružené distribuční funkce). *Pokud je F sdružená distribuční funkce d -rozměrného náhodného vektoru \vec{X} , pak platí*

(i) F je po složkách neklesající a zprava spojitá;

(ii) $\lim_{x_l \rightarrow -\infty} F(\vec{x}) = 0$ pro každé $l = 1 \dots d$;

(iii) $\lim_{x_l \rightarrow +\infty \forall l} F(\vec{x}) = 1$.

Důkaz. Nejdříve dokážeme vlastnost (i). Fixujme $x_1, \dots, x_{l-1}, x_{l+1}, \dots, x_d \in \mathbb{R}$ a definujeme funkci $G(x) := F_{\vec{X}}(x_1, \dots, x_{l-1}, x, x_{l+1}, \dots, x_d)$. Z monotonie pravděpodobnosti je G neklesající a nezáporná. Jelikož je G neklesající, nutně existuje limita $\lim_{y \rightarrow x^+} G(y) \geq G(x)$. Dokážeme, že dochází k rovnosti (čímž dokážeme spojitost zprava).

Z Heineovy věty plyne, že $\lim_{y \rightarrow x^+} G(y) = \lim G(x + \frac{1}{n})$. Označme $B_n := (-\infty, x_1] \times \dots \times (-\infty, x_{l-1}] \times (-\infty, x + \frac{1}{n}) \times (-\infty, x_{l+1}] \times \dots \times (-\infty, x_n]$. Potom máme, že $B_n \searrow B := (-\infty, x_1] \times \dots \times (-\infty, x_{l-1}] \times (-\infty, x] \times (-\infty, x_{l+1}] \times \dots \times (-\infty, x_n]$.

Dále s využitím věty o spojitosti míry (Věta 1.7) můžeme psát

$$\lim_{y \rightarrow x^+} G(y) = \lim_{n \rightarrow \infty} G(x + \frac{1}{n}) = \lim_{n \rightarrow \infty} P_{\vec{X}}(B_n) = P_{\vec{X}}\left(\bigcap_{n=1}^{\infty} B_n\right) = P_{\vec{X}}(B) = G(x),$$

čímž je ukončen důkaz vlastnosti (i).

K důkazu vlastnosti (ii) opět mějme pevná $x_1, \dots, x_{l-1}, x_{l+1}, \dots, x_d \in \mathbb{R}$. Opět uvažujme funkci G z předchozí části důkazu, která je neklesající a nezáporná. Proto musí existovat její limita $\lim_{\vec{x} \rightarrow -\infty} = \lim_{n \rightarrow \infty} G(-n)$ (opět plyne z Heineovy věty). Definujme $C_n := (-\infty, x_1] \times \dots \times (-\infty, x_{l-1}] \times (-\infty, -n] \times (-\infty, x_{l+1}] \times \dots \times (-\infty, x_n]$, potom platí že $C_n \searrow \emptyset$. Podobným argumentem jako posledně máme

$$\lim_{x_l \rightarrow -\infty} F(\vec{x}) = \lim_{x \rightarrow -\infty} G(x) = \lim_{n \rightarrow \infty} G(-n) = \lim_{n \rightarrow \infty} P_{\vec{X}}\left(\bigcap_{n=1}^{\infty} C_n\right) = P_{\vec{X}}(\emptyset) = 0,$$

čímž jsme dokázali vlastnost (ii).

Nakonec si uvědomíme, že podmínka z vlastnosti (iii) je ekvivalentní tomu, že $\lim_{n \rightarrow \infty} \min\{x_l\} = \infty$. Z již několikrát použité věty o spojitosti pravděpodobnosti máme, že $1 \geq F_{\vec{X}}(\vec{x}) \geq F_{\vec{X}}(\min\{x_l\}[1, \dots, 1]^T)$. Stačí tedy dokázat, že poslední uvedená limita je rovna ∞ .

Položme $H(x) := F_{\vec{X}}(x[1, \dots, 1]^T)$. Z monotonie pravděpodobnosti máme, že funkce H je neklesající. Dále $0 \leq H(x) \leq 1$, tedy existuje $\lim_{x \rightarrow \infty} H(x) = \lim_{n \rightarrow \infty} H(n)$ (jako limita posloupnosti). Položme $D_n := (-\infty, n]^d$. Opět z věty o spojitosti míry můžeme psát

$$\lim_{x_l \rightarrow +\infty \forall l} F(\vec{x}) = \lim_{n \rightarrow \infty} H(n) = \lim_{n \rightarrow \infty} P_{\vec{X}}(D_n) = P_{\vec{X}}(\mathbb{R}^d) = 1,$$

čímž jsme získali požadovanou rovnost. \square

Věta 2.37 (Marginální distribuční funkce). *Pokud je $F_{\vec{X}}$ sdružená distribuční funkce náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$, pak*

$$\lim_{x_d \rightarrow +\infty} F_{\vec{X}}(x_1, \dots, x_d) = F(x_1, \dots, x_{d-1}), \forall \vec{x} = [x_1, \dots, x_d]^T \in \mathbb{R}^d,$$

kde F je distribuční funkce náhodného podvektoru $[X_1, \dots, X_{d-1}]^T$.

Důkaz. Nechť je dána libovolná posloupnost $\{z_n\}_{n=1}^\infty$ taková, že $\lim z_n = \infty$. Dále označme $B := \bigcap_{l=1}^{d-1} \{X_l \leq x_l\}$, $B_n := B \cup \{X_d \leq z_n\}$ a $D_n := (\bigcup_{m=n}^\infty B_m^C)^C$. Platí $D_n \subseteq B_n \subseteq B = \bigcup_{m=1}^\infty B_m$ a $D_n \nearrow B$. Ze spojitosti míry (Věta 1.7) máme, že $\lim_{n \rightarrow \infty} P(D_n) = P(B)$ a z monotonie míry máme, že $P(D_n) \leq P(B_n) \leq P(B)$. Potom (viz věta o dvou strážnících) máme $\lim_{n \rightarrow \infty} P(B_n) = P(B)$. Nakonec z Heineovy věty máme, že $\lim_{x_d \rightarrow \infty} P(B \cap \{X_d \leq x_d\}) = P(B)$. \square

Výše zmíněný limitní přechod můžeme opakovat vícekrát a “marginalizovat” až na jednorozměrný případ. Navíc, složky můžeme permutovat, tedy v kombinaci s touto větou můžeme “vyřadit” libovolnou složku.

Definice 2.38 (Marginální rozdelení). Nechť $J \subseteq \{1, \dots, d\}$ a $|J| = m$. Potom *náhodný podvektor* definujeme jako $\vec{Y} \equiv \{X_l\}_{l \in J} : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}^m, \mathcal{B}(\mathbb{R}^m))$ a *marginálním rozdelením* rozumíme indukovanou pravděpodobnostní míru $P_{\vec{Y}}$ na prostoru $(\mathbb{R}^m, \mathcal{B}(\mathbb{R}^m))$.

Ve speciálním případě $J = \{1, \dots, m\}$ pak máme $P_{\vec{Y}}(B) = P_{\vec{X}}(B \times \mathbb{R}^{d-m})$. Pro $|J| = 1$ celkem snadno vidíme, že se jedná o náhodnou veličinu.

V následujících definicích definujeme spojité a diskrétní náhodné vektory podobně tomu, jak jsme to udělali u náhodných veličin.

Definice 2.39. Náhodný vektor $\vec{X} = [X_1, \dots, X_d]^T$ nazveme *diskrétní*, jestliže existují nejvýše spočetná množina $I \subseteq \mathbb{N}$ a posloupnosti $\{\vec{x}_i\}_{i \in I}$ prvků \mathbb{R}^d a $\{p_i\}_{i \in I}$ prvků intervalu $(0, 1]$ takové, že platí

$$P_{\vec{X}} = \sum_{i \in I} p_i \delta_{\vec{x}_i} \text{ a } \sum_{i \in I} p_i = 1,$$

kde $\delta_{\vec{u}}$ značí Diracovu míru v $\vec{u} \in \mathbb{R}^d$.

Definice 2.40. Náhodný vektor $\vec{X} = [X_1, \dots, X_d]^T$ nazveme (*absolutně*) *spojitý*, jestliže $P_{\vec{X}}$ je absolutně spojitá vůči d -rozměrné Lebesgueově mře λ^d .

V případě diskrétního náhodného vektora pak můžeme explicitně uvést sdruženou distribuční funkci $F_{\vec{X}}(\vec{x}) = \sum_{i \in I} p_i \chi_{[\vec{x}_i, \infty)}(\vec{x}) = \sum_{i \in I} \sum_{\vec{x}_i \leq \vec{x}} p_i$, kde relaci \leq uvažujeme po složkách (musí platit pro všechny složky zároveň).

Pro spojité náhodné vektory si uvědomíme, že sdružená distribuční funkce má derivaci $\frac{\partial^d}{\partial x_1 \dots \partial x_d} F_{\vec{X}}$ s.v. vzhledem k λ^d a platí následující vztah pro sdruženou hustotu

$$f_{\vec{X}}(\vec{x}) = \frac{\partial^d}{\partial x_1 \dots \partial x_d} F_{\vec{X}}.$$

Tento vztah platí λ^d -skoro všude a navíc v námi zkoumaných příkladech je $F_{\vec{X}}$ dostatečně hladká, tedy nezáleží na pořadí derivací. Potom také můžeme z hustoty spočítat distribuční funkci pomocí vztahu

$$F_{\vec{X}}(\vec{x}) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_d} f_{\vec{X}}(t_1, \dots, t_d) dt_d \dots dt_1,$$

pro všechna $\vec{x} = [x_1, \dots, x_d]^T \in \mathbb{R}^d$. Díky Fubiniově větě opět nezáleží na pořadí integrálů.

konec 6. přednášky (4.3.2025)

Věta 2.41 (Hustota vzhledem k součinové referenční míře). *Nechť $P_{\vec{X}}$ je rozdělení náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ a nechť existují σ -konečné míry $\mu_l, l \in \{1, \dots, d\}$ na \mathbb{R} takové, že pro jejich součin platí $P_{\vec{X}} \ll \mu_1 \otimes \dots \otimes \mu_d$. Potom $P_{X_l} \ll \mu_l$ pro všechny složky $l \in \{1, \dots, d\}$. Dále pak existují nezáporné měřitelné funkce (hustoty) $f_{\vec{X}} : \mathbb{R}^d \rightarrow [0, \infty)$ a $f_{X_l} : \mathbb{R} \rightarrow [0, \infty)$ pro $l \in \{1, \dots, d\}$ takové, že*

$$P_{\vec{X}}(\times_{l=1}^d (-\infty, x_l]) = F_{\vec{X}}(\vec{x}) = \int_{\times_{l=1}^d (-\infty, x_l]} f_{\vec{X}}(\vec{t}) d(\mu_1 \otimes \dots \otimes \mu_d)$$

pro všechna $\vec{x} = [x_1, \dots, x_d]^T$. Pro borelovskou množinu $B \in \mathcal{B}(\mathbb{R}^d)$ navíc platí

$$P_{\vec{X}}(B) = \int_B f_{\vec{X}}(\vec{t}) d(\mu_1 \otimes \dots \otimes \mu_d).$$

Potom také $F_{X_l}(x_l) = \int_{-\infty}^{x_l} f_{X_l}(t) d\mu_l$ pro všechna $x_l \in \mathbb{R}$ a všechny složky $l \in \{1, \dots, d\}$, kde

$$f_{X_l}(t) = \int_{\mathbb{R}^{d-1}} f_{\vec{X}}(t_1, \dots, t_d) d(\mu_1 \otimes \dots \otimes \mu_{l-1} \otimes \mu_{l+1} \otimes \dots \otimes \mu_d)$$

platí μ_l -skoro všude.

Důkaz. Existence hustot plyne přímo z Radonovy-Nikodymovy věty. Zbytek plyne z Fubiniho věty (předpoklady splněny díky Radonově-Nikodymově větě a faktu, že pravděpodobnostní prostor je vždy normalizovaný). \square

Poznamenejme, že předpoklad existence příslušných měr je automaticky splněn v případě diskrétních nebo absolutně spojitých náhodných vektorů.

Příklad 2.42. Mějme absolutně spojitý náhodný vektor $[X, Y]^T$. Potom existuje jeho sdružená distribuční funkce $F_{[X, Y]^T}(x, y)$. Chceme-li dostat jednorozměrnou distribuční funkci $F_X(x)$, s použitím Věty 2.37 dostáváme $F_X(x) = \lim_{y \rightarrow \infty} F_{[X, Y]^T}(x, y)$. Potom jeho hustotu dosteneme, zderivováním $f_X(x) = F'_X(x)$. Navíc z předchozí věty (Věta 2.41) máme, že existuje sdružená hustota $f_{[X, Y]^T}(x, y) = \frac{\partial^2}{\partial x \partial y} F_{[X, Y]^T}(x, y)$. Pro získání jednorozměrné hustoty f_X pak už jen stačí zintegrovat podle y přes celou reálnou osu.

Nechť \vec{X} je diskrétní náhodný vektor a ν čítací míra na $\{\vec{x}_i\}_{i \in I} \subset \mathbb{R}^d$, pak hustotu tohoto vektoru vzhledem k čítací míře ν nazýváme *pravděpodobnostní funkci* diskrétního mnohorozměrného rozdělení \vec{X} .

Příklad 2.43. Uvažujme dvojrozměrný náhodný vektor $[X, Y]^T$. Pro přehlednost uvedeme i řádkové/sloupcové součty (jde o marginální hustoty).

	$Y = 0$	$Y = 1$	
$X = 0$	1/9	2/9	1/3
$X = 1$	2/9	4/9	2/3
	1/3	2/3	1

Potom přímým výpočtem můžeme získat například $f_{[X,Y]^T}(1,1) = P(X=1, Y=1) = 4/9$.

Příklad 2.44. Nechť dvouozměrný náhodný vektor $[X, Y]^T$ je rovnoměrně rozdělen na jednotkovém čtverci. Pak z Věty 2.41 okamžitě vychází $f_{[X,Y]^T}(x, y) = \chi_{\{(x,y) \in [0,1]^2\}}$. Určíme $P[X < 1/2, Y < 1/2]$. Tato událost $B := \{X < 1/2, Y < 1/2\}$ odpovídá podmnožině jednotkového čtverce, tedy zintegrováním přes tuto podmnožinu nepočítáme nic jiného než plošný obsah této množiny. Z Fubiniovy věty tedy dostáváme $P(B) = 1/4$.

Uvedeme užitečný důsledek předchozí věty pouze v případě dvouozměrných vektorů, snadno se však dají rozšířit i pro případ vícerozměrných vektorů.

Důsledek 2.45 (Marginální rozdělení pro dvouozměrné náhodné vektory). *Pokud diskrétní náhodný vektor $[X, Y]^T$ má sdruženou pravděpodobnostní funkci $f_{[X,Y]^T}$, pak marginální pravděpodobnostní funkce pro X je*

$$f_X(x) = P[X = x] = \sum_y P(X = x, Y = y) = \sum_y f_{[X,Y]^T}(x, y).$$

Pokud spojitý náhodný vektor $[X, Y]^T$ má sdruženou pravděpodobnostní funkci $f_{[X,Y]^T}$, pak marginální hustota pro X je

$$f_X(x) = \int f_{[X,Y]^T}(x, y) dy.$$

Věnujme opět pozornost pojmu nezávislosti náhodných veličin. Všimněme si, že platí následující vlastnost

$$\lim_{x_j \rightarrow \infty \forall j \in \{1, \dots, d\} \setminus l} F_{\vec{X}}(\vec{x}) = \lim_{x_j \rightarrow \infty \forall j \in \{1, \dots, d\} \setminus l} P[X_1 \leq x_1, \dots, X_d \leq x_d] = \\ P[X_l \leq x_l] =: F_{X_l}(x_l).$$

Definice 2.46. Náhodné veličiny X_1, \dots, X_d jsou *nezávislé*, pokud $F_{\vec{X}}(\vec{x}) = \prod_{l=1}^d F_{X_l}(x_l)$ pro každý vektor $\vec{x} = [x_1, \dots, x_d]^T \in \mathbb{R}^d$.

Analogicky s předchozí definicí definujeme nezávislost náhodných vektorů. V literatuře se vyskytuje i jiná, ekvivaletní, definice nezávislosti, kterou uvedeme později.

Definice 2.47. Náhodné vektory $\vec{X}_1, \dots, \vec{X}_d$ jsou *nezávislé*, pokud

$$F_{\vec{X}}(\vec{x}) = \prod_{l=1}^d F_{\vec{X}_l}(\vec{x}_l)$$

pro každý “nad-vektor” $\vec{x} = [\vec{x}_1^T, \dots, \vec{x}_d^T]^T \in \mathbb{R}^{\sum_{l=1}^d d_l}$ kde $\vec{X} = [\vec{X}_1^T, \dots, \vec{X}_d^T]^T$ a \vec{X}_l jsou d_l -rozměrné náhodné vektory pro všechna $l \in \{1, \dots, d\}$.

Dalším důležitým pojmem je takzvaný nosič náhodné veličiny. Rozumíme tím v zásadě množinu, kde náhodná veličina “žije”. Uvedeme zde definici pro diskrétní a spojité náhodné veličiny. Tyto pojmy se budou hodit pro vymezení prostoru, přes který poté budeme integrovat.

Definice 2.48. *Nosičem diskrétní náhodné veličiny X nazýváme následující množinu $S(X) = \{x \in \mathbb{R} : P[X = x] > 0\}$. Nosičem spojité náhodné veličiny Y rozumíme množinu $S(Y) = \{y \in \mathbb{R} : f_Y(y) > 0\}$. Obdobně definujeme i nosič náhodného vektoru (cvičení).*

Věta 2.49 (Ekvivalentní charakterizace nezávislosti). *Nechť sdružená pravděpodobnostní funkce diskrétního náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ je $f_{\vec{X}}(\vec{x}) = P[\vec{X} = \vec{x}]$. Pak platí, že náhodné veličiny $\{X_1, \dots, X_d\}$ jsou nezávislé právě tehdy, když*

$$P[\vec{X} = \vec{x}] = \prod_{l=1}^d P[X_l = x_l]$$

pro všechny vektory $\vec{x} = [x_1, \dots, x_d]^T \in \times_{l=1}^d S(X_l)$.

Nechť sdružená pravděpodobnostní funkce spojitého náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ je $f_{\vec{X}}(\vec{x})$. Pak platí, že $\{X_1, \dots, X_d\}$ jsou nezávislé právě tehdy, když

$$P[\vec{X} = \vec{x}] = \prod_{l=1}^d f_{X_l}(x_l)$$

pro λ^d -skoro všechny vektory $\vec{x} = [x_1, \dots, x_d]^T \in \times_{l=1}^d S(X_l)$.

Důkaz. Dokážeme oba případy (spojitý a diskrétní) najednou tak, že budeme uvažovat příslušnou referenční součinovou míru.

Nejdříve dokážeme implikaci \Rightarrow . Uvažujme vektor $\vec{x} = [x_1, \dots, x_d]^T$. Potom z definice nezávislosti a linearity integrálu dostáváme

$$F_{\vec{X}}(\vec{x}) = \prod_{l=1}^d F_{X_l}(x_l) = \prod_{l=1}^d \int_{-\infty}^{x_l} f_{x_l}(t_l) d\mu_l = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_d} \prod_{l=1}^d f_{x_l}(t_l) d\mu_d \cdots d\mu_1,$$

kde druhá rovnost plyne z věty o hustotě vzhledem k součinové referenční míře (Věta 2.41) s mírou λ^d , případně sčítací mírou ν na \mathbb{R}^d . Dále díky Fubiniově větě můžeme pokračovat v úpravách

$$\int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_d} \prod_{l=1}^d f_{x_l}(t_l) d\mu_d \cdots d\mu_1 = \int_{(-\infty, \vec{x}]} \prod_{l=1}^d f_{x_l}(t_l) d(\mu_1 \otimes \cdots \otimes \mu_d).$$

Pak už ale nutně musí platit $f_{\vec{X}}(t_1, \dots, t_d) = \prod_{l=1}^d f_{x_l}(t_l)$.

Implikace \Leftarrow se dokáže obráceným postupem (cvičení). \square

Důsledek 2.50. Předpokládejme, že $S([X, Y]^T) = S(X) \times S(Y)$. Pokud pro sdruženou pravděpodobnostní funkci diskrétního náhodného vektoru $[X, Y]^T$ platí $P[X = x, Y = y] = g(x)h(y)$ pro nějaké měřitelné funkce g, h a pro všechna $[x, y]^T \in S([X, Y]^T)$, pak X a Y jsou nezávislé.

Obdobně, pokud pro sdruženou pravděpodobnostní funkci spojitého náhodného vektoru $[X, Y]^T$ platí $f_{[X, Y]^T}(x, y) = g(x)h(y)$ pro nějaké měřitelné funkce g, h a pro λ^2 -skoro všechna $[x, y]^T \in S([X, Y]^T)$, pak X a Y jsou nezávislé.

Poznámka: g a h nutně nemusí být hustoty nebo pravděpodobnostní funkce, ale normovaná funkce $\tilde{g} := \frac{g}{\int g}$ již ano.

Důkaz. Definujme \tilde{g} a \tilde{h} jako v poznámce. Potom musí existovat verze $\tilde{g}, \tilde{h} \geq 0$ měřitelná. Zbytek dostaneme z předchozí věty. \square

konec 7. přednášky (10.3.2025)

Věta 2.51 (Alternativní (ekvivalentní) definice nezávislosti). Náhodné veličiny X_1, \dots, X_d jsou nezávislé právě tehdy, když

$$P_{\vec{X}} = \otimes_{l=1}^d P_{X_l}.$$

Důkaz. Začneme implikací zprava doleva (\Leftarrow). Jestliže pro všechny množiny $B_l \in \mathcal{B}(\mathbb{R}), l = 1, \dots, d$ platí

$$P_{\vec{X}}(\times_{l=1}^d B_l) = \prod_{l=1}^d P_{X_l}(B_l),$$

pak vezmeme $B_l = (-\infty, x_l]$ pro fixní $\vec{x} = [x_1, \dots, x_d]$ generátory borelovské σ -algebry a můžeme počítat

$$F_{\vec{X}}(\vec{x}) = P_{\vec{X}}(\times_{l=1}^d (-\infty, x_l]) = \prod_{l=1}^d P_{X_l}((-\infty, x_l]) = \prod_{l=1}^d F_{X_l}(x_l),$$

což je přímo definice nezávislosti.

K důkazu opačné implikace (předpokládáme platnost $F_{\vec{X}}(\vec{x}) = \prod_{l=1}^d F_{X_l}(x_l)$ pro všechna $\vec{x} \in \mathbb{R}^d$) použijeme Dynkinův systém

$$D = \left\{ \times_{l=1}^d (-\infty, x_l], x_l \in \mathbb{R}, \forall l \in \{1, \dots, d\} \right\}.$$

Tento systém je uzavřený na průniky a generuje celou borelovskou σ -algebrou $\mathcal{B}(\mathbb{R}^d)$. Jelikož $P_{\vec{X}}(\mathbb{R}^d) = 1$, dostáváme z věty o jednoznačnosti míry rovnost obou mér ($P_{\vec{X}}$ a $\otimes_{l=1}^d P_{X_l}$) na celé $\mathcal{B}(\mathbb{R}^d)$. \square

Vrátíme se opět k podmíněnosti, tentokrát budeme zkoumat podmíněnost náhodných veličin. Motivačním příkladem budí zjištění průměrné mzdy občana, který vystudoval MatFyz na základě znalosti průměrné mzdy všech občanů ČR. Opět se jedná o zjednodušenou definici, ta obecnější bude uvedena v pokročilejších kurzech.

Definice 2.52. Pro diskrétní náhodný vektor $[X, Y]^T$ definujeme *podmíněnou pravděpodobnostní funkci* X za podmínky $Y = y$ vztahem

$$f_{X|Y}(x|y) \equiv P[X = x|Y = y] := \frac{P[X = x, Y = y]}{P[Y = y]} \equiv \frac{f_{[X,Y]^T}(x,y)}{f_Y(y)},$$

pokud $P[Y = y] > 0$.

Pro spojité náhodný vektor $[X, Y]^T$ je *podmíněná hustota* X za podmínky $Y = y$

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

pokud $f_Y(y) > 0$.

Je třeba si uvědomit, že podmíněná pravděpodobnostní funkce (hustota) jsou funkce argumentu x s parametrem y . V případech nepokrytých touto definicí můžeme definovat podmíněnou pravděpodobnost libovolně. Několik užitečných vzorců pro výpočet podmíněné pravděpodobnosti, pro diskrétní vektor platí $P[X \in A|Y = y] = \sum_{x \in A} P[X = x|Y = y]$ a pro spojité vektor platí $P[X \in A|Y = y] = \int_A f_{X|Y}(x|y) dy$.

V dalších kapitolách budeme pracovat s mnohorozměrným normálním rozdělením, je proto vhodné si ho zadefinovat už teď. V obecném případě nestačí zadefinovat chování po složkách, je třeba nějakým způsobem zahrnout i vztahy mezi jednotlivými složkami.

Definice 2.53. Náhodný vektor $\vec{X} = [X_1, \dots, X_d]^T$ má *d-rozměrné normální rozdělení* s parametry $\mu \in \mathbb{R}^d$ a $\Sigma \in \mathbb{R}^{d \times d}$ (značíme $X \sim N_d(\mu, \Sigma)$), pokud existuje k -rozměrný náhodný vektor $\vec{Y} = [Y_1, \dots, Y_k]^T$ a matice $\mathbb{A} \in \mathbb{R}^{d \times k}$ takové, že

- (i) $\{Y_1, \dots, Y_k\}$ jsou nezávislé;
- (ii) $Y_j \sim N(0, 1)$ pro všechny složky $j \in \{1, \dots, k\}$;
- (iii) $\mathbb{A}\mathbb{A}^T = \Sigma$;
- (iv) $\vec{X} = \mathbb{A}\vec{Y} + \mu$.

Takto komplikovaná definice je potřeba, neboť matice Σ nutně nemusí mít jednoznačně určenou “druhou odmocninu”, proto musíme použít nějakou druhou odmocninu, která bude případně dávat nižší hodnotu. Takto definovaná matice \mathbb{A} a vektor μ jsou deterministické (nenáhodné). Pozornost si zaslouží tzv. standardní d -rozměrné normální rozdělení $N_d(\vec{0}, I_d)$.

Na závěr se budeme chvíli věnovat transformacím náhodných veličin. V obecném případě je možné formalizovat tuto představu pomocí vety o substituci z TMI, avšak pro naše účely postačí uvést jen několik speciálních případů.

Mějme diskrétní náhodnou veličinu X a ne nutně monotónní funkci $t : \mathbb{R} \rightarrow \mathbb{R}$, pro kterou platí $Y := t(X)$. Chceme odvodit pravděpodobnostní funkci

$P[Y = y]$. Můžeme psát

$$P[Y = y] = P[t(X) = y] = P[X \in t^{-1}(y)] = \sum_{t(x)=y} P[X = x].$$

Dále mějme spojitou náhodnou veličinu X , známe její hustotu $f_X(x)$. Cílem je spočítat hustotu $f_Y(y)$, kde $Y = t(X)$. Pro každé y můžeme nalézt množinu $\mathcal{T}_y = \{x : t(x) \leq y\}$. Poté můžeme spočítat distribuční funkci rozdělení Y .

$$F_Y(y) = P[Y \leq y] = P[t(X) \leq y] = P[\omega : t(X(\omega)) \leq y] = \int_{\mathcal{T}(y)} f_X(x) dx,$$

hustotu poté můžeme získat pouhým zderivováním distribuční funkce F_y .

Dále uvažujme případ (dvourozměrného) diskrétního náhodného vektoru $[X, Y]^T$ a transformace $Z = t(X, Y)$. Ze znalosti diskrétního rozdělení vektoru $[X, Y]$ chceme spočítat $P[Z = z]$. Můžeme psát

$$P[Z = z] = P[t(X, Y) = z] = P[\omega : t([X, Y]^T(\omega)) = z] =$$

$$P[[X, Y]^T \in t^{-1}(z)] = \sum_{t(x,y)=z} P[X = x, Y = y].$$

Nakonec mějme spojitý náhodný vektor $[X, Y]^T$, pro nějž známe hustotu $f_{[X,Y]^T}(x, y)$ a chceme získat hustotu $f_Z(z)$, jestliže náhodná veličina Z je definována $Z := t(X, Y)$. V analogii se spojitou náhodnou veličinou nalezneme pro každé $z \in \mathbb{R}$ množinu $\mathcal{T}(z) = \{[x, y] : t(x, y) \leq z\}$. Opět spočteme distribuční funkci F_Z pomocí následujících kroků

$$F_Z(z) = P[Z \leq z] = P[t(X, Y) \leq z] = P[\omega : t([X, Y]^T(\omega)) \leq z] =$$

$$\iint_{\mathcal{T}(z)} f_{[X,Y]^T}(x, y) dx dy,$$

hustotu f_Z opět můžeme získat pomocí zderivování funkce F_Z .

3 Střední hodnota

V této kapitole se budeme věnovat pojmu střední hodnoty, laicky řečeno, kolem jaké hodnoty se nachází naše rozdělení. Nejedná se ani o průměr ani o prostřední, případně nejčastější hodnotu, tyto pojmy zadefinujeme později a ve statistice mají svůj vlastní význam odlišný od střední hodnoty.

Definice 3.1. *Střední hodnota* náhodné veličiny X je reálné číslo

$$\mathbb{E}[X] = \mathbb{E}X = \int X dP \equiv \int X(\omega) dP(\omega),$$

pokud pravá strana existuje.

Tato definice je velmi teoretická, k praktickému výpočtu se hodí následující věta, kde převedeme integrál na výpočet pomocí obrazu pravděpodobnostní míry.

Věta 3.2. *Střední hodnota náhodné veličiny X je $\mathbb{E}X = \int x dP_X(x)$, pokud pravá strana existuje.*

Důkaz. Z věty o přenosu integrace (2.5) při volbě $g = Id$ a $(\mathbb{M}, \mathcal{M}) = (\mathbb{R}, \mathcal{B})$ dostáváme požadované tvrzení. \square

Z Radon-Nikodymovy věty ihned plyne následující pozorování

Pozorování 3.3. *Střední hodnota veličiny X je*

$$\mathbb{E}X = \begin{cases} \int_{-\infty}^{\infty} xf_X(x) dx, & X \text{ spojitá;} \\ \sum_{x \in S(X)} x P[X = x], & X \text{ diskrétní.} \end{cases}$$

Střední hodnota nemusí existovat vždy, jeden z takových případů uvedeme v následujícím příkladu.

Příklad 3.4. Pokud $X \sim Cauchy$ (Definice 2.32), pak $\mathbb{E}X$ neexistuje. Pomocí integrování per partes můžeme počítat

$$\int_0^\infty \frac{x}{\pi(1+x^2)} dx = [x \arctan(x)]_0^\infty - \int_0^\infty \arctan(x) dx = \infty.$$

Dostali jsme, že pro integrál přes celou reálnou přímku není definován výraz $\infty - \infty$.

Uvažujme teď transformaci $Y = t(X)$. Následující věta nám umožní počítat střední hodnotu transformované náhodné veličiny.

Věta 3.5 (Pravidlo líného statitika). *Budě $t : \mathbb{R} \rightarrow \mathbb{R}$ měřitelná funkce a nechť $Y = t(X)$, kde X je nějaká náhodná veličina. Pak*

$$\mathbb{E}Y = \int t(x) dP_X(x),$$

pokud pravá strana existuje.

Důkaz. Z Věty 2.5 dostáváme

$$\mathbb{E}Y = \mathbb{E}[t(X)] = \int_{\mathbb{R}} t(X(\omega))dP(\omega) = \int_{\mathbb{R}} t(x)dP_X(x).$$

□

Poznamenejme si explicitní vzorce pro transformaci spojitých a diskrétní náhodných veličin, které jsou přímým důsledkem předchozí věty:

Důsledek 3.6. *Mějme náhodné veličiny X a Y takové, že platí $Y = t(X)$ pro nějakou transformaci $t : \mathbb{R} \rightarrow \mathbb{R}$. Má-li X diskrétní rozdělení, potom*

$$\mathbb{E}Y = \sum_{x \in S(x)} t(x)P[X = x].$$

Je-li X spojitá, potom platí

$$\mathbb{E}Y = \int_{\mathbb{R}} t(x)f_X(x)dx.$$

Přímé využití pravidla líného statistika si uvedeme v definici a aplikacích následujícího pojmu, který jistým způsobem umožnuje charakterizovat chování rozdělení.

Definice 3.7. Pro reálné číslo k definujeme k -tý *moment* náhodné veličiny X jako $\mathbb{E}[X^k]$ za předpokladu, že $\mathbb{E}[|X|^k] < \infty$. Dále definujeme k -tý *absolutní moment* jako $\mathbb{E}[|X|^k]$, pokud existuje.

V praxi se nejčastěji setkáme s momenty jen pro k přirozené, pokud nebude řečeno jinak, všechny momenty budou mít přirozený parametr.

Věta 3.8. *Pokud existuje k -tý moment, pak existuje l -tý moment pro jakékoli $l \in \{1, \dots, k\}$.*

Důkaz. Potřebujeme ukázat, že $\mathbb{E}[|X|^l] < \infty$. Můžeme počítat

$$\begin{aligned} \mathbb{E}[|X|^l] &= \int_{\mathbb{R}} |x|^l dP_X(x) = \int_{|x| \leq 1} |x|^l dP_X(x) + \int_{|x| > 1} |x|^l dP_X(x) \leq \\ &\leq \int_{|x| \leq 1} dP_X(x) + \int_{|x| > 1} |x|^k dP_X(x) \leq \int_{\mathbb{R}} dP_X(x) + \int_{\mathbb{R}} |x|^k dP_X(x). \end{aligned}$$

Dostáváme $1 + \mathbb{E}[|X|^k] < \infty$, čímž je důkaz ukončen. □

Některá zobrazení mají jen několik prvních momentů a žádné vyšší momenty neexistují, jako například Studentovo t -rozdělení (Definice 2.31) s $\nu = 3$ stupni volnosti.

Příklad 3.9. Pro $X \sim t_3$ platí $\mathbb{E}X = 0$, $\mathbb{E}X^2 = 2$ ale $\mathbb{E}|X|^3 = \infty$. (cvičení, použijte per partes)

Definujeme dále \mathcal{L}^p prostory náhodných veličin, které jsou podobné L^p prostorům z teorie míry a funkcionální analýzy.

Definice 3.10. Pro reálné číslo p (v praxi se vystačíme pouze s případem $p \geq 1$) definujeme prostor \mathcal{L}^p tak, že náhodná veličina $X \in \mathcal{L}^p$, jestliže $\mathbb{E}[|X|^p] < \infty$.

Ukážeme si pár základních vlastností prostoru \mathcal{L}^1 , které se mohou hodit při praktických aplikacích.

Věta 3.11 (Základní vlastnosti prostoru \mathcal{L}^1). *Nechť jsou dány $X_1, \dots, X_d \in \mathcal{L}^1$ a a_1, \dots, a_d jsou konstanty, pak platí linearita ve smyslu*

$$\mathbb{E} \left(\sum_{l=1}^d a_l X_l \right) = \sum_{l=1}^d a_l \mathbb{E} X_l.$$

Dále mějme $X_1, \dots, X_d \in \mathcal{L}^1$ nezávislé náhodné veličiny, potom platí

$$\mathbb{E} \left(\prod_{l=1}^d X_l \right) = \prod_{l=1}^d \mathbb{E} X_l.$$

Důkaz. Linearita plyne z věty o přenosu integrace (Věta 2.5) a linearity Lebesgueova integrálu.

Dokážeme druhou vlastnost. Nejprve ukážeme, že hledaná střední hodnota je dobře definovaná. Uvažujme posloupnost funkcí $\{g_n : \mathbb{R}^d \rightarrow \mathbb{R}\}$ definovaných jako $g_n(\vec{x}) = \prod_{l=1}^d |x_l| \chi_{\{|x_l| \leq n\}}$. Pak pro každé $n \in \mathbb{N}$ je $g_n(\vec{X})$ omezená a existuje její první moment $\mathbb{E}[g_n(\vec{X})] \in \mathbb{R}$. Díky nezávislosti můžeme psát

$$\mathbb{E}[g_n(\vec{X})] = \int_{\mathbb{R}^d} \prod_{l=1}^d |x_l| \chi_{\{|x_l| \leq n\}} d(\otimes_{l=1}^d P_{X_l}),$$

odkud z Fubiniovy věty a následně linearity integrálu plyne

$$= \int_{\mathbb{R}} \cdots \int_{\mathbb{R}} \prod_{l=1}^d |x_l| \chi_{\{|x_l| \leq n\}} dP_{X_1} \cdots dP_{X_d} = \prod_{l=1}^d \mathbb{E}[|X_l| \chi_{\{|X_l| \leq n\}}] \leq \prod_{l=1}^d \mathbb{E}[|X_l|].$$

Platí, že funkce $g_n(\vec{x})$ jsou nezáporné a $g_n(\vec{x}) \uparrow \prod_{l=1}^d |x_l|$ na celém \mathbb{R}^d . Tudíž z Leviho věty plyne, že $\mathbb{E}[g_n(\vec{X})] \uparrow \mathbb{E}[\prod_{l=1}^d |X_l|]$. Potom ale nutně $\mathbb{E} \left[\prod_{l=1}^d X_l \right] \leq \prod_{l=1}^d \mathbb{E}|X_l| < \infty$, tedy příslušný první moment existuje.

Dále můžeme počítat

$$\begin{aligned} \mathbb{E} \left[\prod_{l=1}^d X_l \right] &= \int_{\mathbb{R}^d} \prod_{l=1}^d x_l dP_{\vec{X}} = \int_{\mathbb{R}} \prod_{l=1}^d x_l d(\otimes_{l=1}^d P_{X_l}) = \\ &= \int_{\mathbb{R}} \cdots \int_{\mathbb{R}} \prod_{l=1}^d x_l dP_{X_1} \cdots dP_{X_d} = \prod_{l=1}^d \int_{\mathbb{R}} x_l dP_{X_l} = \prod_{l=1}^d \mathbb{E} X_l, \end{aligned}$$

kde druhá rovnost plyne z nezávislosti náhodných veličin X_1, \dots, X_d , třetí z Fubiniovy věty a předposlední z linearity integrálu. \square

konec 8. přednášky (11.3.2025)

Ted definiujeme další neplnohodnotnou (jinými slovy, neurčuje danou náhodnou veličinu, případně její rozdelení jednoznačně) charakteristiku. (Poznámka: příkladem plnohodnotné charakteristiky je distribuční funkce rozdelení)

Definice 3.12. Rozptyl náhodné veličiny X je definován jako

$$\text{Var } X = \mathbb{E}(X - \mathbb{E}X)^2,$$

za předpokladu, že pravá strana je dobře definovaná. Pak *směrodatná odchylka* tytéž náhodné veličiny je definovaná je

$$\text{sd}(X) = \sqrt{\text{Var } X}.$$

Uvědomme si, že některé volby charakterizování variability rozdělení nejsou vhodné, například na první pohled logické “ $\mathbb{E}(X - \mathbb{E}X)$ ” je nulová všude, kde je definovaná.

Věta 3.13 (Vlastnosti rozptylu). Za předpokladu, že uvažované druhé momenty jsou konečné, potom

$$\text{Var } X = \mathbb{E}(X^2) - (\mathbb{E}(X))^2 \geq 0.$$

Pokud $a, b \in \mathbb{R}$, pak

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

jinými slovy, rozptyl se chová jako kvadratická forma. Pokud X_1, \dots, X_d jsou nezávislé a a_1, \dots, a_d jsou reálné konstanty, pak

$$\text{Var} \left(\sum_{l=1}^d a_l X_l \right) = \sum_{l=1}^d a_l^2 \text{Var } X_l.$$

Důkaz. Dokážeme první vlastnost. Máme

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

kde předposlední rovnost plyne z linearity střední hodnoty a faktu, že $E[c] = c$ pro konstantu c . Nezápornost plyne z toho, že počítáme střední hodnotu nezáporné náhodné veličiny.

Dále pro druhou vlastnost pišme

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

kde druhá rovnost plyne z linearity střední hodnoty a rovnosti $b = \mathbb{E}b$, dále můžeme psát

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

K důkazu poslední vlastnosti začneme opět rozepsáním definice

$$\begin{aligned} \text{Var}\left(\sum_{l=1}^d a_l X_l\right) &= \mathbb{E}\left[\sum_{l=1}^d a_l X_l - \mathbb{E}\left(\sum_{l=1}^d a_l X_l\right)^2\right] = \mathbb{E}\left[\sum_{l=1}^d a_l(X_l - \mathbb{E}X_l)\right]^2 = \\ &= \mathbb{E}\left[\sum_{l=1}^d a_l^2(X_l - \mathbb{E}X_l)^2 + 2 \sum_{1 \leq j < l \leq d} a_j a_l (X_j - \mathbb{E}X_j)(X_l - \mathbb{E}X_l)\right] = \\ &= \sum_{l=1}^d a_l^2 \mathbb{E}(X_l - \mathbb{E}X_l)^2 + 2 \sum_{1 \leq j < l \leq d} a_j a_l \mathbb{E}(X_j - \mathbb{E}X_j)(X_l - \mathbb{E}X_l) = \sum_{l=1}^d a_l^2 \text{Var } X_l, \end{aligned}$$

kde poslední rovnost plyne z toho, že v případě $j \neq l$ máme díky nezávislosti

$$\mathbb{E}(X_j - \mathbb{E}X_j)(X_l - \mathbb{E}X_l) = E[X_j X_l] - \mathbb{E}[X_l] \mathbb{E}[X_j] = 0.$$

□

Dalším pojmem, kterému se budeme věnovat, je kovariance a korelace, které charakterizují lineární vztah mezi dvěma náhodnými veličinami.

Definice 3.14. Kovariance mezi X a Y je definována jako

$$\text{Cov}(X, Y) = E((X - \mathbb{E}X)(Y - \mathbb{E}Y)).$$

Pokud $\text{Var}(X) \text{Var}(Y) > 0$, pak definujeme korelacii mezi X a Y vztahem

$$\rho_{X,Y} \equiv \text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \text{Var}(Y)}}.$$

Je třeba si dávat pozor, že tyto pojmy necharakterizují libovolnou souvislost mezi náhodnými veličinami, ale pouze lineární. Navíc, korelace nemusí způsobovat kauzalitu (spotřeba čokolády v dané zemi sice koreluje s počtem Nobelových laureátů, ale nemůžeme zvýšit počet laureátů tím, že zvýšíme spotřebu čokolády).

Dále si všimneme, že z pravidla líného statistika (Věta 3.5) okamžitě plynou následující vztahy.

Důsledek 3.15. Pro X, Y spojité platí $\mathbb{E}XY = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_{(X,Y)}(x, y) dx dy$.
Pro X, Y diskrétní platí $\mathbb{E}XY = \sum_{x \in S(X), y \in S(Y)} xy P[X = x, Y = y]$.

Dále si zformulujeme několik vlastností kovariance a korelace.

Věta 3.16. Pro náhodné veličiny X a Y platí následující tvrzení (jsou-li příslušné matematické objekty dobře definovány).

$$(i) \text{ Cov}(X, Y) = \mathbb{E}(XY) - \mathbb{E}X \mathbb{E}Y;$$

$$(ii) -1 \leq \text{Corr}(X, Y) \leq 1;$$

(iii) $|\text{Corr}(X, Y)| = 1 \Leftrightarrow Y = aX + b$ s pravděpodobností 1 pro nějaké hodnoty $a, b \in \mathbb{R}$.

(iv) Pro nezávislé X a Y platí $\text{Cov}(X, Y) = 0$. Pozor: opačná implikace nemusí platit (stačí vzít $X \sim U(-1, 1), Y = X^2$).

Důkaz. Budeme postupovat postupně, k důkazu první vlastnosti použijeme následující výpočet:

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

kde druhá rovnost se získá roznásobením závorek analogicky s důkazem předchozí věty. Z tohoto okamžité plyne vlastnost (iv), neboť nezávislost X a Y implikuje, že $\mathbb{E}(XY) = \mathbb{E}X\mathbb{E}Y$.

K důkazu vlastnosti (ii) použijeme Cauchyovu-Schwarzovu nerovnost (Věta 4.4), kterou si zde dokážeme. Definujeme funkci $g(a) := \mathbb{E}(aX - Y)^2$, potom

$$0 \leq \mathbb{E}(aX - Y)^2 = \mathbb{E}(a^2X^2 - 2aXY + Y^2) = a^2\mathbb{E}X^2 - 2a\mathbb{E}XY + \mathbb{E}Y^2.$$

Funkci $g(a)$ můžeme zderivovat, dostáváme

$$g'(a) = 2a\mathbb{E}X^2 - 2\mathbb{E}XY,$$

svého minima tedy funkce g nabývá v bodě $\frac{\mathbb{E}XY}{\mathbb{E}X^2}$ (bez újmy na obecnosti $\mathbb{E}X^2 \neq 0$, v opačném případě máme $X = 0$ skoro jistě, z čehož vlastnosti z věty plynou triviálně). Dosadíme tuto hodnotu do předpisu funkce $g(a)$ a dostáváme.

$$g\left(\frac{\mathbb{E}XY}{\mathbb{E}X^2}\right) = \frac{(\mathbb{E}XY)^2}{\mathbb{E}X^2} - 2\frac{(\mathbb{E}XY^2)}{\mathbb{E}X^2} + \mathbb{E}Y^2 \geq 0.$$

Z toho již plyne, že $(\mathbb{E}XY)^2 \leq (\mathbb{E}X^2)(\mathbb{E}Y^2)$ (dokázali jsme Cauchy-Schwarzel!), z čehož plyne požadované tvrzení.

Vlastnost (iii) budeme dokazovat po implikacích. Nejdříve předpokládejme, že $Y = aX + b$ pro nějaká $a, b \in \mathbb{R}$. Potom máme

$$\begin{aligned} \text{Cov}(X, Y) &= \text{Cov}(X, aX + b) = \mathbb{E}[X(aX + b)] - \mathbb{E}X\mathbb{E}(aX + b) = \\ &= a\mathbb{E}X^2 + b\mathbb{E}X - a(\mathbb{E}X)^2 - b\mathbb{E}X = a \text{Var } X. \end{aligned}$$

a můžeme psát

$$|\text{Corr}(X, Y)| = \frac{|\text{Cov}(X, Y)|}{\sqrt{\text{Var } X \text{Var } Y}} = \frac{|a \text{Var } X|}{\sqrt{\text{Var } X a^2 \text{Var } X}} = 1.$$

Nakonec, k důkazu poslední implikace si uvědomíme, že rovnost nastává v případě $|\text{Corr}(X, Y)| = \sqrt{\text{Var } X \text{Var } Y}$. To nastane právě tehdy, když

$$[\mathbb{E}(X - \mathbb{E}X)(Y - \mathbb{E}Y)]^2 = [\mathbb{E}(X - \mathbb{E}X)^2][\mathbb{E}(Y - \mathbb{E}Y)^2].$$

Položme $\tilde{X} = X - \mathbb{E}X$ a $\tilde{Y} = Y - \mathbb{E}Y$. Předchozí výraz pak bude mít tvar

$$[\mathbb{E}\tilde{X}\tilde{Y}]^2 = \mathbb{E}\tilde{X}^2\mathbb{E}\tilde{Y}^2.$$

Dosadíme $a = \frac{\mathbb{E}\tilde{X}\tilde{Y}}{\mathbb{E}\tilde{X}^2}$ do $g(a)$ z důkazu vlastnosti (ii), dostáváme (všimněte si, že jde o bod, kde funkce g nabývá svého minima) $0 = \mathbb{E} \left[\frac{\mathbb{E}\tilde{X}\tilde{Y}}{\mathbb{E}\tilde{X}^2} \tilde{X} - \tilde{Y} \right]^2$, a tedy musí platit $P[a\tilde{X} - \tilde{Y} = 0] = 1$. Pak s pravděpodobností 1 musí platit $aX - a\mathbb{E}X + \mathbb{E}Y = Y$, což jsme chtěli dokázat (stačí vzít $b = -a\mathbb{E}X - \mathbb{E}Y$). \square

Jednoduchým důsledkem tohoto tvrzení (plyne z důkazu poslední vlastnosti Věty 3.13) je následující tvrzení umožňující počítat rozptyl součtu ne nutně nezávislých veličin.

Důsledek 3.17 (Rozptyl součtu). *Pokud $X_1, \dots, X_d \in \mathcal{L}^2$ a a_1, \dots, a_d jsou reálné konstanty, potom*

$$\text{Var} \left(\sum_{l=1}^d a_l X_l \right) = \sum_{l=1}^d a_l^2 \text{Var} X_l + 2 \sum_{1 \leq j < l \leq d} a_j a_l \text{Cov}(X_j, X_l).$$

Pro vícerozměrné náhodné vektory můžeme definovat obdobné pojmy jako pro náhodné veličiny.

Definice 3.18. *Střední hodnotu* náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ definujeme předpisem

$$\mathbb{E}\vec{X} = [\mathbb{E}X_1, \dots, \mathbb{E}X_d]^T.$$

Varianční-kovarianční matice náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ je definována jako

$$\text{Var } \vec{X} = \begin{bmatrix} \text{Var} X_1 & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_d) \\ \text{Cov}(X_2, X_1) & \text{Var} X_2 & \cdots & \text{Cov}(X_2, X_d) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_d, X_1) & \text{Cov}(X_d, X_2) & \cdots & \text{Var}(X_d) \end{bmatrix}.$$

Všimneme si, že platí $\text{Cov}(X, X) = \text{Var} X$ a $\text{Cov}(X, Y) = \text{Cov}(Y, X)$. Z toho plyne, že takto definovaná kovarianční matice je symetrická a navíc $\text{Var } \vec{X} [\text{Cov}(X_i, X_j)]_{i,j=1 \dots d}$.

konec 9. přednášky (17.3.2025)

Budeme pokračovat základními vlastnostmi variančních matic, které se chovaly podobně rozptylu jednorozměrné náhodné veličiny.

Věta 3.19 (Vlastnosti varianční matice). *Máme-li náhodný vektor \vec{X} a reálné vektory \vec{a}, \vec{b} takové, že následující výrazy mají smysl, potom*

$$\mathbb{E}(\vec{a}^T \vec{X} + \vec{b}) = \vec{a}^T \mathbb{E}\vec{X} + \vec{b}, \text{Var}(\vec{a}^T \vec{X} + \vec{b}) = \vec{a}^T (\text{Var } \vec{X}) \vec{a}.$$

Máme-li náhodný vektor \vec{X} a \vec{A}, \vec{B} jsou reálné maticy, pak

$$\mathbb{E}(A\vec{X} + B) = A\mathbb{E}\vec{X} + B, \text{Var}(A\vec{X} + B) = A(\text{Var } \vec{X})A^T.$$

Důkaz. Z definice násobení matic a linearity operátoru \mathbb{E} . \square

Definice 3.20. Pro danou náhodnou veličinu X definujeme *momentovou vytvářející funkci* (MGF) vztahem

$$\psi_X(t) = \mathbb{E}[\exp(tx)] = \int_{\mathbb{R}} e^{tx} dP_X(x)$$

pro $t \in \mathbb{R}$, pokud pravá strana existuje. Speciální případ $\psi_X(-t)$ nazýváme *Laplaceovou transformací* X .

Věta 3.21 (Vlastnosti MGF). *Platí následující vlastnosti MGF:*

- (i) Existuje-li $\varepsilon > 0$ takové, že na $(-\varepsilon, \varepsilon)$ existuje $\psi_X(t)$, potom $\psi_X^{(m)}(0) = \mathbb{E}X^m, m \in \mathbb{N}_0$;
- (ii) Pokud $Y = aX + b$, pak $\psi_Y(t) = e^{bt}\psi_X(at)$;
- (iii) Pokud X_1, \dots, X_d jsou nezávislé a $Y = \sum_{l=1}^d X_l$, pak platí $\psi_Y(t) = \prod_{l=1}^d \psi_{X_l}(t)$.

Důkaz. Dokážeme první vlastnost. Případ $m = 0$ je triviální, nechť tedy máme $m > 0$. Nejdříve budeme uvažovat případ $m = 1$ a chceme použít větu o konvergentní majorantě. Nechť tedy

$$g(x) := e^{-\frac{\varepsilon x}{2}} + e^{\frac{\varepsilon x}{2}},$$

potom platí $\exp tx \leq g(x)$ pro všechna $t \in [-\varepsilon/2, \varepsilon/2]$ a libovolné $x \in \mathbb{R}$. Dále z předpokladu máme, že

$$\int_{\mathbb{R}} g(x) dP_X(x) = \psi_X(-\varepsilon/2) + \psi_X(\varepsilon/2) < +\infty.$$

Dostáváme, že g je hledaná konvergentní majoranta. Z věty o konvergentní majoranty tedy můžeme provést záměnu integrálu a derivace.

$$\frac{d}{dt} \psi(t) = \frac{d}{dt} \int_{\mathbb{R}} e^{tx} dP_X(x) = \int_{\mathbb{R}} xe^{tx} dP_X(x) \stackrel{t=0}{=} \int_{\mathbb{R}} x dP_X(x) = \mathbb{E}X^1.$$

Zbytek se dokáže indukcí s použitím podobné majoranty, v m -tému kroku dostaneme $\int_{\mathbb{R}} x^m dP_X(x) =: \mathbb{E}X^m$.

Druhou vlastnost dokážeme přímým rozepsáním definice

$$\begin{aligned} \psi_Y(t) &= \psi_{aX+b}(t) = \mathbb{E}[\exp(taX + tb)] = \mathbb{E}[\exp\{atX\}e^{tb}] = \\ &= e^{tb}\mathbb{E}[\exp(atX)] = e^{tb}\psi_X(at). \end{aligned}$$

Nakonec, poslední vlastnost se dokáže následně

$$\psi_Y(t) = \psi_{\sum_{l=1}^d X_l}(t) = \mathbb{E}[\exp\{t \sum_{l=1}^d X_l\}] = \mathbb{E}\left[\prod_{l=1}^d e^{tX_l}\right].$$

Dále využijeme nezávislost (která se přenáší i na veličiny transformované stejnou měřitelnou funkcí) a dostaneme

$$\mathbb{E} \left[\prod_{l=1}^d e^{tX_l} \right] = \prod_{l=1}^d \mathbb{E}(e^{tX_l}) = \prod_{l=1}^d \psi_{X_l}(t).$$

□

Poznámka: pokud $\psi_X(t) = \psi_Y(t)$ pro všechna t v nějakém otevřeném intervalu kolem 0, pak X a Y se rovnají v distribuci.

Definice 3.22. Pro danou náhodnou veličinu X definujeme *charakteristickou funkci* (CF) vztahem

$$\varphi_X(t) = \mathbb{E}[\exp(itX)] = \int_{\mathbb{R}} e^{itx} dP_X(x)$$

pro $t \in \mathbb{R}$.

Na rozdíl od momentové vytvořující funkce takto definovaná charakteristická funkce je dobře definovaná pro všechna $t \in \mathbb{R}$. Opět máme speciální název pro vyhodnocení charakteristické funkce v bodě $-t$, říkáme tomu *Fourierova transformace*. Z definice exponenciály z komplexní analýzy okamžitě dostáváme vyjádření $\phi_X(t) = \mathbb{E} \cos(tX) + i\mathbb{E} \sin(tX)$.

Věta 3.23 (Vlastnosti CF). *Platí následující vlastnosti CF:*

- (i) φ_X existuje pro jakékoli rozdělení X ;
- (ii) $\varphi_X(0) = 1$;
- (iii) $|\varphi_X(t)| \leq 1$ pro všechna $t \in \mathbb{R}$;
- (iv) φ_X je stejnoměrně spojitá, tedy $\forall \varepsilon > 0 \exists \delta > 0 : |\varphi_X(t) - \varphi_X(s)| \leq \varepsilon$ když $|t - s| \leq \delta$;
- (v) $\varphi_{aX+b}(t) = e^{ibt}\varphi_X(at)$ pro všechna $t, a, b \in \mathbb{R}$;
- (vi) $\varphi_{-X}(t) = \bar{\varphi}_X(t)$ (komplexně sdružená funkce);
- (vii) $\varphi_X(t) \in \mathbb{R} \forall t \in \mathbb{R}$ právě tehdy když rozdělení je symetrické kolem bodu $t = 0$.
- (viii) Jsou-li X, Y nezávislé, potom $\varphi_{X+Y}(t) = \varphi_X(t)\varphi_Y(t)$.

Důkaz. Budeme dokazovat vlastnosti postupně

- (i) Víme, že pro všechna x a všechna t platí $|e^{itx}|^2 = \sin^2(tx) + \cos^2(tx) = 1$. Pak $\mathbb{E}|e^{itx}|^2 = 1$, z Jensenovy nerovnosti (bude později) máme, že $\mathbb{E}|e^{itx}| \leq \sqrt{\mathbb{E}|e^{itx}|^2} = 1$ a tedy e^{itx} je integrovatelná.
- (ii) Přímým dosazením dostaneme $\int_{\mathbb{R}} dP_X(x) = 1$.

(iii) Viz důkaz vlastnosti (i).

(iv) Položme $h := s - t$, potom

$$\begin{aligned} |\varphi_X(t) - \varphi_X(s)| &= |\mathbb{E}[e^{itX}] - \mathbb{E}[e^{i(t+h)X}]| \leq \\ &\leq \mathbb{E}[|e^{itX}(1 - e^{ihX})|] \leq \\ &\leq \mathbb{E}[|e^{itX}| \cdot |1 - e^{ihX}|] \leq \mathbb{E}[|e^{ihX} - 1|]. \end{aligned}$$

Víme, že $e^{ihX} - 1 \rightarrow 0$ když $h \rightarrow 0$ a zároveň $|e^{ihX} - 1| \leq 2$. Máme tedy konvergentní majorantu. Dle Lebesgueovy věty tedy platí $\lim_{h \rightarrow 0} \mathbb{E}[|e^{ihX} - 1|] = 0$. Z toho již plyne stejnoměrná spojitost.

(v) Z definice dostáváme

$$\varphi_{aX+b}(t) = \mathbb{E}e^{it(aX+b)} = e^{ibt}\mathbb{E}e^{itaX} = e^{ibt}\varphi_X(at).$$

(vi) Využijeme přepisu do goniometrického tvaru (viz poznámka před touto větou), dostaneme

$$\varphi_{-X}(t) = \mathbb{E}[\cos(-tX) + i\sin(-tX)] = \mathbb{E}[\cos(tX) - i\sin(tX)] = \bar{\varphi}_X(t).$$

(vii) Nechť nejdříve X má rozdělení symetrické kolem 0, potom $X \stackrel{d}{=} -X$, z čehož máme $\varphi_{-X}(t) = \varphi_X(t)$. Aplikací již dokázané vlastnosti (v) máme, že $\varphi_X = \bar{\varphi}_X(t)$, tedy $\varphi_X(t) \in \mathbb{R}$. Opačná implikace se dokáže stejným postupem v opačném pořadí.

(viii) Rozepsání definice

$$\varphi_{X+Y}(t) = \mathbb{E}[e^{it(X+Y)}] = \mathbb{E}[e^{itX}e^{itY}],$$

dále díky nezávislosti dostáváme

$$\mathbb{E}[e^{itX}e^{itY}] = \mathbb{E}[e^{itX}]\mathbb{E}[e^{itY}] = \varphi_X(t)\varphi_Y(t).$$

□

Následující věta nám umožňuje jednoznačně popisovat rozdělení jak podle distribuční funkce, tak i podle charakteristické funkce.

Věta 3.24 (Leviho inverzní formule pro charakteristickou funkci). *Pro jakékoli rozdělení X a libovolné $a < b$ platí*

$$\lim_{T \rightarrow \infty} \frac{1}{2\pi} \int_{-T}^T \frac{e^{-ita} - e^{-itb}}{it} \varphi_X(t) dt = P[a < X < b] + \frac{P[X = a] + P[X = b]}{2}.$$

Důkaz. Mějme $T \in \mathbb{R}$ a $a < b$, potom

$$\begin{aligned} \frac{1}{2\pi} \int_{-T}^T \frac{e^{ita} - e^{itb}}{it} \varphi_X(t) dt &= \frac{1}{2\pi} \int_{-T}^T \frac{e^{ita} - e^{itb}}{it} \int_{\mathbb{R}} e^{itx} dP_X = \\ \int_{-T}^T \int_{-\infty}^{\infty} \frac{e^{it(x-a)} - e^{it(x-b)}}{2\pi it} dP_X dt &\stackrel{Fubini}{=} \int_{-\infty}^{\infty} \int_{-T}^T \frac{e^{it(x-a)} - e^{it(x-b)}}{2\pi it} dt dP_X. \end{aligned}$$

Všimneme si, že pro každou konstantu $c \in \mathbb{R}$ platí $\int_{-T}^T \frac{e^{itc}}{2it} dt = \int_0^T \frac{\sin(tc)}{t} dt$ a tento integrál se navíc rovná $\frac{\pi}{2} \operatorname{sgn}(c)$. Potom platí

$$\begin{aligned} \frac{1}{2\pi} \int_{-T}^T \frac{e^{ita} - e^{itb}}{it} \varphi_X(t) dt &= \\ \int_{-\infty}^{\infty} \frac{1}{\pi} \left[\int_0^T \frac{\sin(t(x-a))}{t} dt - \int_0^T \frac{\sin(t(x-b))}{t} dt \right] dP_X. \end{aligned}$$

Když pošleme T do nekonečna, dostaneme následující hodnoty

$$\frac{1}{\pi} \int_0^T \frac{\sin(t(x-a))}{t} dt \stackrel{T \rightarrow \infty}{\rightarrow} \begin{cases} -\frac{1}{2}, & x < a, \\ \frac{1}{2}, & x > a, \\ 0, & x = a. \end{cases}$$

Potom

$$\frac{1}{\pi} \left[\int_0^T \frac{\sin(t(x-a))}{t} dt - \int_0^T \frac{\sin(t(x-b))}{t} dt \right] \stackrel{T \rightarrow \infty}{\rightarrow} \begin{cases} \frac{1}{2}, & x = a, b \\ 1, & a < x < b, \\ 0, & \text{jinak.} \end{cases}$$

Dosazením do předchozího vzorce a užitím Lebesgueovy věty o konvergentní majorantě dostaváme

$$\frac{1}{2\pi} \int_{-T}^T \frac{e^{ita} - e^{itb}}{it} \varphi_X(t) dt = P[a < X < b] + \frac{P[X = a] + P[X = b]}{2}.$$

□

Z předchozí věty okamžitě plyne následující důsledek.

Důsledek 3.25 (Jednoznačná charakterizace rozdělení). *Platí $\varphi_X = \varphi_Y \Leftrightarrow X \stackrel{d}{=} Y$.*

Nakonec definujeme charakteristickou funkci pro náhodné vektory. Obdobným způsobem pro ní můžeme dokázat vlastnosti, které jsme již dokázali pro jednorozměrné náhodné veličiny.

Definice 3.26. Charakteristická funkce náhodného vektoru $\vec{X} = [X_1, \dots, X_d]^T$ je definována vztahem

$$\varphi_{\vec{X}}^{\vec{t}} = \mathbb{E}[e^{i\vec{t}^T \vec{X}}] = \int_{\mathbb{R}} e^{i\vec{t}^T \vec{X}} dP_{\vec{X}}$$

pro $\vec{t} \in \mathbb{R}^d$.

konec 10. přednášky (18.3.2025)

4 Stochastické nerovnosti

V této kapitole budeme studovat užitečné nerovnosti, které budeme moci aplikovat pro odhady některých statistických veličin. Začneme odhady pro hodnoty pravděpodobnosti samotné (tzv. nerovnosti Markovovského typu)

Věta 4.1 (Markovova nerovnost). *Nechť X je nezáporná náhodná veličina a předpokládejme, že $\mathbb{E}X$ existuje. Potom pro každé $\varepsilon > 0$ platí*

$$P[X \geq \varepsilon] \leq \frac{\mathbb{E}X}{\varepsilon}.$$

Důkaz. Z předpokladu máme, že $X \geq 0$, tedy $P[X \geq 0] = 1$ a $P[X < 0] = 1 - 1 = 0$. Z toho plyne, že

$$\int_{\{\omega \in \Omega : X(\omega) < 0\}} dP(\omega) = 0.$$

Potom pro $\varepsilon > 0$ máme, že pravděpodobnost

$$\begin{aligned} P[X \geq \varepsilon] &= \int_{\{\omega \in \Omega : X(\omega) \geq \varepsilon\}} dP(\omega) \leq \int_{\{\omega \in \Omega : X(\omega) \geq \varepsilon\}} \frac{X(\omega)}{\varepsilon} dP(\omega) \leq \\ &\quad \int_{\Omega} \frac{X(\omega)}{\varepsilon} dP(\omega) = \frac{1}{\varepsilon} \int_{\Omega} X(\omega) dP(\omega) = \frac{\mathbb{E}X}{\varepsilon}, \end{aligned}$$

kde první nerovnost platí díky tomu, že $X(\omega) > \varepsilon$ a tedy $\frac{X(\omega)}{\varepsilon} > 1$. \square

Důsledek 4.2 (Zobecněná Markovova nerovnost). *Nechť X je nezáporná náhodná veličina a předpokládejme, že $\mathbb{E}X^r$ existuje pro nějaké $r > 0$. Potom pro každé $\varepsilon > 0$ platí*

$$P[X \geq \varepsilon] \leq \frac{\mathbb{E}X^r}{\varepsilon^r}.$$

Důkaz. Nechť $Y := X^r$, $\tilde{\varepsilon} = \varepsilon^r$, poté použijeme předchozí větu pro $P[Y \leq \tilde{\varepsilon}]$. \square

Věta 4.3 (Čebyševova nerovnost). *Nechť X je náhodná veličina a předpokládejme, že $\mathbb{E}[X]$ existuje, potom pro každé $\varepsilon > 0$ platí*

$$P[|X - \mathbb{E}X| \geq \varepsilon] \leq \frac{\text{Var}[X]}{\varepsilon^2}.$$

Důkaz. Položme $Y = |X - \mathbb{E}X| \geq 0$ a $\tilde{\varepsilon} = \varepsilon^2$, potom stačí aplikovat Větu 4.1. \square

Dále si uvedeme několik nerovností, které přímo poskytují odhad pro střední hodnotu.

Věta 4.4 (Cauchy-Schwarzova nerovnost). *Pokud mají náhodné veličiny X a Y konečné rozptyly, potom*

$$|\mathbb{E}XY| \leq \sqrt{\mathbb{E}X^2 \mathbb{E}Y^2} \quad a \quad |\text{Cov}(X, Y)| \leq \sqrt{\text{Var } X \text{ Var } Y}.$$

Důkaz. Plyne z důkazu vlastnosti (ii) ve Větě 3.16 o vlastnostech kovariance a korelace. \square

Věta 4.5 (Jensenova nerovnost). *Pokud je g konvexní, pak $\mathbb{E}g(X) \geq g(\mathbb{E}X)$. Dále, pokud je g konkávní $\mathbb{E}g(X) \leq g(\mathbb{E}X)$.*

Důkaz. Nechť máme $t(x) = a + tx$ tečna k funkci g v bodě $\mathbb{E}X$. Pokud g je konvexní, pak $t(x) \leq g(x)$ pro všechna $x \in \mathbb{R}$. Také platí $t(\mathbb{E}X) = g(\mathbb{E}X)$. Potom $E[g(X)] \geq E[t(X)] = E[a + bX] = a + b\mathbb{E}X = t(\mathbb{E}X) = g(\mathbb{E}X)$. Pro konkávní g se tvrzení dokáže analogicky. \square

5 Stochastické konvergence

V této kapitole budeme studovat druhý konvergence v pravděpodobnostních prostorech, které jsou často jiné, neboť náš prostor je vždy normovaný na 1.

Definice 5.1. Nechť X_1, X_2, \dots je posloupnost náhodných veličin a nechť X je jiná náhodná veličina. Nechť F_n označuje distribuční funkci X_n a nechť F označuje distribuční funkci X . Potom X_n konverguje k X v pravděpodobnosti (předpokládáme, že X_i, X všechny „žijí“ na stejném pravděpodobnostním prostoru), značíme $X_n \xrightarrow[n \rightarrow \infty]{P} X$, pokud pro každé $\varepsilon > 0$,

$$P[|X_n - X| > \varepsilon] \xrightarrow{n \rightarrow \infty} 0.$$

Dále X_n konverguje k X v distribuci, značíme $X_n \xrightarrow[n \rightarrow \infty]{D} X$, pokud

$$\lim_{n \rightarrow \infty} F_n(x) = F(x)$$

pro všechna x kde je F spojitá.

X_n konverguje k X v L_p pro $p \geq 1$, značíme $X_n \xrightarrow[n \rightarrow \infty]{L^p} X$, pokud

$$\mathbb{E}|X_n - X|^p \xrightarrow{n \rightarrow \infty} 0.$$

X_n konverguje k X skoro jistě, značíme $X_n \xrightarrow[n \rightarrow \infty]{P-s.j.} X$, pokud

$$P[\lim_{n \rightarrow \infty} X_n = X] \equiv P[\omega \in \Omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)] = 1.$$

Věta 5.2 (Implikace mezi typy konvergence). Platí následující implikace

$$(i) \quad X_n \xrightarrow[n \rightarrow \infty]{P-s.j.} X \implies X_n \xrightarrow[n \rightarrow \infty]{P} X;$$

$$(ii) \quad \text{pro } p \geq 1 \text{ platí } X_n \xrightarrow[n \rightarrow \infty]{L^p} X \implies X_n \xrightarrow[n \rightarrow \infty]{P} X;$$

$$(iii) \quad \text{pro } p \geq q \geq 1 \text{ platí } X_n \xrightarrow[n \rightarrow \infty]{L^p} X \implies X_n \xrightarrow[n \rightarrow \infty]{L^q} X;$$

$$(iv) \quad X_n \xrightarrow[n \rightarrow \infty]{P} X \implies X_n \xrightarrow[n \rightarrow \infty]{D} X;$$

$$(v) \quad \text{Pokud } X_n \xrightarrow[n \rightarrow \infty]{D} X \text{ a } P[X = c] = 1 \text{ pro nějaké } c \in \mathbb{R}, \text{ pak } X_n \xrightarrow[n \rightarrow \infty]{P} X.$$

konec 11. přednášky (24.3.2025)

Důkaz. Budeme dokazovat postupně každou implikaci.

(i) Mějme $\varepsilon > 0$. Pro $n \in \mathbb{N}$ definujeme náhodné události

$$A_n := \{\omega \in \Omega : \exists m \geq n : |X_m(\omega) - X(\omega)| \geq \varepsilon\};$$

$$B_n := \{\omega \in \Omega : |X_n(\omega) - X(\omega)| \geq \varepsilon\}.$$

Chceme ukázat, že $P(B_n) \rightarrow 0$. Víme, že $A_n \supseteq B_n$, tedy díky monotonii pravděpodobnosti stačí ukázat, že $P(A_n) \rightarrow 0$. Reálná posloupnost $\{X_m(\omega)\}_m$ je konvergentní, jestliže existuje přirozené číslo N takové, že pro žádné $m \geq N$ neplatí $|X_m(\omega) - X(\omega)| \geq \varepsilon$. Potom $\lim A_n$ je jev, že posloupnost $\{X_m(\omega)\}_m$ diverguje. Ale dle předpokladu X_n konverguje skoro jistě, tedy $P(\lim A_n) = 0$. Jelikož $A_1 \supset A_2 \supset \dots$, z věty o spojitosti míry (Věta 1.7) dostáváme $P(\lim A_n) = \lim P(A_n) = 0$, čímž jsme dostali požadovanou konvergenci v pravděpodobnosti.

- (ii) Nechť $X_n \xrightarrow{L_p} X$. Podle Markovovy nerovnosti (Věta 4.1) platí

$$P(|X_n - X| \geq \varepsilon) = P(|X_n - X|^p \geq \varepsilon^p) \leq \frac{\mathbb{E}|X_n - X|^p}{\varepsilon^p} \rightarrow 0$$

pro $n \rightarrow \infty$, neboť se jedná o posloupnost čísel a chování čitatele vyplývá z předpokladu konvergence v L_p .

- (iii) Nechť $X_n \xrightarrow{L_p} X$ a $p \geq q \geq 1$. Dle Jensenovy nerovnosti pro konvexní funkci (Věta 4.5) $g(x) := x^{p/q}$ pro $x \geq 0$ dostáváme $g(\mathbb{E}[|X_n - X|^q]) \leq \mathbb{E}[|X_n - X|^{q \cdot \frac{p}{q}}] = \mathbb{E}|X_n - X|^p \rightarrow 0$, kde limitní přechod plyne z předpokladu konvergence v L_p , tedy jsme přímo ukázali konvergenci v L_q .
- (iv) Nechť $X_n \xrightarrow{P} X$. Zvolme $\varepsilon > 0$ libovolně. Nechť $x \in \mathbb{R}$ je libovolný bod, v němž je limitní distribuční funkce F spojitá. Potom můžeme psát

$$\begin{aligned} F_n(x) &= P(X_n \leq x) = P(X_n \leq x, X \leq x + \varepsilon) + P(X_n \leq x, X > x + \varepsilon) \leq \\ &P(X \leq x + \varepsilon) + P(|X_n - X| > \varepsilon) = F(x + \varepsilon) + P(|X_n - X| > \varepsilon). \end{aligned}$$

Takto dostaneme

$$\begin{aligned} F(x - \varepsilon) &= P(X \leq x - \varepsilon) = P(X \leq x - \varepsilon, X_n \leq X) + \\ &P(X \leq x - \varepsilon, X_n > \varepsilon) \leq F_n(x) + P(|X_n - X| > \varepsilon). \end{aligned}$$

Potom $F(x - \varepsilon) - P(|X_n - X| > \varepsilon) \leq F_n(x) \leq F(x + \varepsilon) + P(|X_n - X| > \varepsilon)$. Jelikož $\varepsilon > 0$ bylo voleno libovolně a F je spojitá v x , tedy $\lim_{n \rightarrow \infty} F_n(x) = F(x)$.

- (v) Nechť $X_n \xrightarrow{D} X$ a nechť $P[X = c] = 1$ pro nějaké $c \in \mathbb{R}$. Zvolme libovolné $\varepsilon > 0$ a můžeme počítat

$$\begin{aligned} P(|X_n - X| \geq \varepsilon) &= P(X_n \leq c - \varepsilon) + P(X_n \geq c + \varepsilon) \leq \\ &P(X_n \leq c - \varepsilon) + P(X_n > c + \frac{\varepsilon}{2}) \leq \\ &F_n(c - \varepsilon) + 1 - F_n(c + \frac{\varepsilon}{2}) \xrightarrow{n \rightarrow \infty} 0 + 1 - 1 = 0, \end{aligned}$$

čímž jsme dokončili důkaz této věty.

□

Uvedeme si několik protipříkladů, na kterých si ukážeme, že implikace opačné k právě uvedeným nemusí platit.

Příklad 5.3. Ukážeme, že konvergence v pravděpodobnosti neimplikuje konvergenci skoro jistě. Mějme prostor $(\Omega = [0, 1], \mathcal{A} = \mathcal{B}(\Omega), P = \lambda)$. Každé přirozené číslo můžeme jednoznačně zapsat ve tvaru $2^n + m$, kde $m \in \{0, 1, \dots, 2^n - 1\}$ a definovat

$$X_{2^n+m}(\omega) = \chi_{\{\omega \in (m2^{-n}, (m+1)2^{-n}]\}}, \omega \in [0, 1].$$

Například, protože $33 = 2^5 + 1$, dostaneme $X_{33}(\omega) = \chi_{\{\omega \in (2^{-5}, 2^{-4}]\}}$. Pak pro každé $\varepsilon \in (0, 1)$ dostaneme $P[|X_{2^n+m}| > \varepsilon] = 2^{-n} \rightarrow 0$ pro $n \rightarrow \infty$. Tedy $X_n \xrightarrow{P} 0$. Avšak pro každé $\omega \in (0, 1]$, $X_j(\omega) = 1$ a $X_j(\omega) = 0$ pro nekonečně mnoho různých j a tedy posloupnost X_n nekonverguje skoro jistě.

Příklad 5.4. Ukážeme, že konvergence v pravděpodobnosti neimplikuje konvergenci v L_p . Mějme prostor $(\Omega = [0, 1], \mathcal{A} = \mathcal{B}(\Omega), P = \lambda)$. Každé přirozené číslo můžeme jednoznačně zapsat ve tvaru $2^n + m$, kde $m \in \{0, 1, \dots, 2^n - 1\}$ a definovat

$$X_{2^n+m}(\omega) = 2^n \chi_{\{\omega \in ((m-1)2^{-n}, m2^{-n}]\}}, \omega \in [0, 1].$$

Pak opět pro každé $\varepsilon \in (0, 1)$ dostaneme $P[|X_{2^n+m}| > \varepsilon] = 2^{-n} \rightarrow 0$. Tedy $X_n \xrightarrow{P} 0$. Nicméně, $\mathbb{E}|X_{2^n+m} - 0| = 2^n P[X_{2^n+m} = 2^n] = 2^n 2^{-n} = 1$ a tedy posloupnost nekonverguje v L_1 , tedy to nemůže konvergovat ani v vyšších $L_p, p > 1$.

Příklad 5.5. Ukážeme, že konvergence v L_q neimplikuje konvergenci v L_p pro $p > q \geq 1$. Mějme prostor $(\Omega = [0, 1], \mathcal{A} = \mathcal{B}(\Omega), P = \lambda)$. Každé přirozené číslo můžeme jednoznačně zapsat ve tvaru $2^n + m$, kde $m \in \{0, 1, \dots, 2^n - 1\}$ a definovat

$$X_{2^n+m}(\omega) = 2^{n/2} \chi_{\{\omega \in ((m-1)2^{-n}, m2^{-n}]\}}, \omega \in [0, 1].$$

Pak $\mathbb{E}|X_{2^n+m} - 0| = 2^{n/2} P[X_{2^n+m} = 2^n] = 2^{n/2} 2^{-n}$ a tedy posloupnost konverguje v L_1 . Nicméně, pro $p = 2$ máme $\mathbb{E}|X_{2^n+m} - 0|^2 = 2^{2(n/2)} 2^{-n} = 1$ tedy posloupnost nekonverguje v L_2 .

Příklad 5.6. Ukážeme, že konvergence v distribuci neimplikuje konvergenci v pravděpodobnosti. Necht $X \sim N(0, 1)$ a $X_n := -X, n \in \mathbb{N}$. Tedy $X_n \sim N(0, 1)$ pro každé $n \in \mathbb{N}$. Tedy triviálně $\lim F_n(x) = F(x)$ pro všechna $x \in \mathbb{R}$. Tedy $X_n \xrightarrow{D} X$.

Nicméně, $P[|X_n - X| > \varepsilon] = P[|2X| > \varepsilon] = P[|X| > \varepsilon/2] \neq 0$ (nezávislé na n), tedy posloupnost X_n nekonverguje v pravděpodobnosti.

Věta 5.7 (o spojitém zobrazení (CMT)). *Necht $\vec{X}, \vec{X}_1, \vec{X}_2, \dots$ jsou d-rozměrné náhodné vektory a $g : \mathbb{R}^d \rightarrow \mathbb{R}^m$ je spojitá v každém bodě množiny C takové, že $P[\vec{X} \in C] = 1$. Potom platí*

- $\vec{X}_n \xrightarrow{P-s.j.} \vec{X} \implies g(\vec{X}_n) \xrightarrow{P-s.j.} g(\vec{X});$
- $\vec{X}_n \xrightarrow{P} \vec{X} \implies g(\vec{X}_n) \xrightarrow{P} g(\vec{X});$
- $\vec{X}_n \xrightarrow{D} \vec{X} \implies g(\vec{X}_n) \xrightarrow{D} g(\vec{X}).$

Důkaz. Dokážeme pouze první dvě vlastnosti. Nejdříve, nechť X_n konverguje skoro jistě, potom ze spojitosti g máme, že vlastnost $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$ implikuje $\lim_{n \rightarrow \infty} g(X_n(\omega)) = g(X(\omega))$. Potom $P[\omega \in \Omega : \lim_{n \rightarrow \infty} g(X_n(\omega)) = g(X(\omega))] = P[\omega \in \Omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)] = 1$, přičemž poslední rovnost plyne z definice konvergence skoro jistě.

K důkazu druhé vlastnosti zvolme $\varepsilon > 0$. Potom uvažujme pro libovolné $\delta > 0$ množinu

$$B_\delta := \{x \in \mathbb{R} : \exists y \in \mathbb{R} : |x - y| < \delta \wedge |g(x) - g(y)| \geq \varepsilon\}.$$

konec 12. přednášky (25.3.2025)

Zřejmě $B_\delta \rightarrow \emptyset$ pro $\delta \rightarrow 0^+$. Potom můžeme psát

$$\begin{aligned} P(|g(\vec{X}_n) - g(\vec{X})| \geq \varepsilon) &= P(|g(\vec{X}_n) - g(\vec{X})| \geq \varepsilon \cap |\vec{X}_n - \vec{X}| \geq \delta) + \\ P(|g(\vec{X}_n) - g(\vec{X})| \geq \varepsilon \cap |\vec{X}_n - \vec{X}| < \delta) &\leq P(|\vec{X}_n - \vec{X}| \geq \delta) + P(\vec{X} \in B_\delta). \end{aligned}$$

Jelikož δ bylo voleno libovolně, platí $P(\vec{X} \in B_\delta) \xrightarrow{\delta \rightarrow 0} 0$ a $P(|\vec{X}_n - \vec{X}| \geq \delta) \xrightarrow{n \rightarrow 0} 0$, čímž jsme dokázali konvergenci v pravděpodobnosti. \square

Poznámka: z $\vec{X}_n \xrightarrow{L_p} \vec{X}$ nutně neplyne $g(\vec{X}_n) \xrightarrow{L_p} g(\vec{X})$.

Dalším významným tvrzením teorie pravděpodobnosti je takzvaná Slutského věta (v anglické literatuře se také používá název Cramer-Slutského věta).

Věta 5.8 (Slutského věta). *Pokud $X_n \xrightarrow{D} X$ a $Y_n \xrightarrow{P} c \in \mathbb{R}$, pak $X_n + Y_n \xrightarrow{D} X + c$ a $X_n Y_n \xrightarrow{D} cX$.*

Důkaz. Dokážeme pouze výrok pro součet, část pro součin se dokáže analogicky.

Mějme $x \in \mathbb{R}$ bod, v němž je spojitá distribuční funkce veličiny $X + c$. Potom $x - c$ je nutně bodem spojitosti distribuční funkce F_X . Zvolme $\eta > 0$. Potom existuje $\varepsilon_0 > 0$ takové, že $|F_X(x - c) - F_X(x - c - \varepsilon)| < \frac{\eta}{3}$ pro každé $|\varepsilon| < \varepsilon_0$.

Jelikož F_X je distribuční funkce, má nejvýše spočetně mnoho bodů nespojitosti. Dokážeme tuto vlastnost. Nechť D je množina bodů nespojitosti F_X . Pak $\forall y \in D : F_X(y_-) < F_X(y_+)$, tedy existuje racionální číslo $q_y \in \mathbb{Q}$ takové, že $F_X(y_-) < q_y < F_X(y_+)$. Jelikož F_X je neklesající, pak $y \neq z \in D \implies q_y \neq q_z$. Tedy zobrazení $y \mapsto q_y$ je prosté.

Z toho máme, že v každém okolí bodu $x - c$ můžeme nalézt vlevo i vpravo od $x - c$ nějaký bod, v němž je F_X spojitá. Z definice spojitosti existuje $0 < \varepsilon < \varepsilon_0$ takové, že F_X je spojitá v $x - c + \varepsilon$ i v $x - c - \varepsilon$. Potom

$$P(X_n + Y_n \leq x) = P(X_n + Y_n \leq x \cap |Y_n - c| < \varepsilon) + P(X_n + Y_n \leq x \cap |Y_n - c| \geq \varepsilon) \leq$$

$$\begin{aligned} P(X_n + c \leq x + \varepsilon \cap |Y_n - c| < \varepsilon) + P(|Y_n - c| \geq \varepsilon) &\leq \\ P(X_n \leq x - c + \varepsilon) + P(|Y_n - c| \geq \varepsilon). \end{aligned}$$

Jelikož F_X je spojitá v bodě $x - c + \varepsilon$ a $Y_n \xrightarrow{P} c$, existuje $n_1 \in \mathbb{N}$ takové, že pro všechna $n \geq n_1$ platí $P(X_n \leq x - c + \varepsilon) \leq P(X_n \leq x - c) + \frac{\eta}{3}$ a zároveň $P(|Y_n - c| \geq \varepsilon) \leq \frac{\eta}{3}$. Dohromady pro $n \geq n_1$ máme

$$P(X_n + Y_n \leq x) \leq P(X \leq x - c + \varepsilon) + \frac{2}{3}\eta \leq P(X \leq x - c) + \eta.$$

Opačná nerovnost se dokáže analogicky. Pro $n \geq \max\{n_1, n_2\}$ dohromady máme

$$P(X + c \leq x) - \eta \leq P(X_n + Y_n \leq x) \leq P(X + c \leq x) + \eta.$$

Jelikož $\eta > 0$ bylo voleno libovolně, věta je dokázana. \square

Z této věty okamžitě plyne následující důsledek (neboť konvergence v pravděpodobnosti implikuje konvergenci v distribuci, viz Věta 5.2, vlastnosti (iv) a (v)).

Důsledek 5.9. Pokud $x_n \xrightarrow{P} a \in \mathbb{R}$ a $Y_n \xrightarrow{P} b \in \mathbb{R}$, potom $X_n + Y_n \xrightarrow{P} a + b$ a $X_n Y_n \xrightarrow{P} ab$.

Ještě budeme potřebovat následující větu, která ekvivalentně charakterizuje konvergenci v distribuci, její důkaz je však aktuálně nad naše schopnosti.

Věta 5.10 (Lévyho věta o spojitosti). Platí $\vec{X}_n \xrightarrow{D} \vec{X} \Leftrightarrow \varphi_{\vec{X}_n}(\vec{t}) \rightarrow \varphi_{\vec{X}}(\vec{t})$ pro všechna $\vec{t} \in \mathbb{R}^d$.

Ukážeme si explicitní vyjádření charakteristické funkce normálního rozdělení.

Příklad 5.11. Nechť $X \sim N(\mu, \sigma^2)$. Potom platí

$$\varphi_X(t) = \exp \left\{ i\mu t - \frac{1}{2}\sigma^2 t^2 \right\}.$$

Důkaz. Nejdříve uvažujme $X \sim N(0, 1)$ standardní normální rozdělení. Potom

$$\begin{aligned} \varphi_X(t) &= \mathbb{E}[\exp\{itx\}] = \mathbb{E}[\cos(tx)] + i\mathbb{E}[\sin(tx)] = \\ &= \int_{-\infty}^{\infty} \cos(tx) dP_X + i \int_{-\infty}^{\infty} \sin(tx) dP_X = \mathbb{E}[\cos(tX)], \end{aligned}$$

kde poslední rovnost plyne z faktu, že sin je lichá funkce, a tedy příslušný integrál je nulový. Zderivujeme $\varphi_X(t)$ s použitím majoranty x .

$$\frac{d}{dt} \varphi_X(t) = - \int_{-\infty}^{\infty} x \sin(tx) dP_X = - \int_{-\infty}^{\infty} x \sin(tx) \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{x^2}{2} \right\} dx =$$

$$\stackrel{p.p.}{=} [x \sin(tx) f_X(x)]_{-\infty}^{\infty} - \int_{-\infty}^{\infty} t \cos(tx) f_X(x) dx = -t \mathbb{E}[\cos(tX)].$$

Dostali jsme, že $\frac{d}{dt} \varphi_X(t) = -t \varphi_X(t)$. Tato diferenciální rovnice s počáteční podmínkou $\varphi_X(0) = \cos 0 = 1$ má jediné řešení $\varphi_X(t) = \exp\left\{-\frac{t^2}{2}\right\}$.

Potom pro $Y = \mu + \sigma X$ ($Y \sim N(\mu, \sigma^2)$) dosadíme a aplikujeme výsledek pro standardní rozdělení, dostaneme

$$\begin{aligned} \varphi_Y(t) &= \mathbb{E}[\exp\{itY\}] = E[\exp\{it(\mu + \sigma X)\}] = \\ &\exp\{it\mu\} \cdot \mathbb{E}[\exp\{i(t\sigma)X\}] = \exp\left\{it\mu - \frac{1}{2}\sigma^2 t^2\right\}. \end{aligned}$$

□

konec 13. přednášky (31.3.2025)

Definice 5.12. Posloupností nezávislých náhodných veličin rozumíme posloupnost náhodných veličin $\{X_n\}_{n \in \mathbb{N}}$ takovou, že pro každou $J \subset \mathbb{N}$, $|J| < \infty$ a všechna $\{x_j\}_{j \in J}$ platí

$$F_{\{X_j\}_{j \in J}}(\{x_j\}_{j \in J}) = \prod_{j \in J} F_{X_j}(x_j).$$

Definice 5.13. $\{X_n\}_{n \in \mathbb{N}}$ je posloupnost nezávislých stejně rozdělených náhodných veličin (IID), jestliže to je posloupnost nezávislých náhodných veličin majících stejnou distribuční funkci.

Tyto definice lze celkem snadno přepsat i pro náhodné vektory (cvičení).

Věta 5.14 (Slabý zákon velkých čísel). Jestliže $\{X_n\}_{n \in \mathbb{N}}$ je IID posloupnost náhodných veličin a $\mathbb{E}|X_1| < \infty$, pak

$$\bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow[n \rightarrow \infty]{P} \mathbb{E}X_1.$$

Důkaz. Rozvineme komplexní exponenciál do Taylorova rozvoje do prvního řádu. Platí $e^{ity} = 1 + ity + o(t)$ pro všechna $y \in \mathbb{R}$. Potom $\mathbb{E}[e^{itY}] = 1 + it\mathbb{E}Y + o(t)$. Dále můžeme počítat

$$\begin{aligned} \varphi_{\bar{X}_n}(t) &= \varphi_{\frac{1}{n} \sum X_i}(t) = \varphi_{\frac{\sum X_i}{n}}(t) = \left(\varphi_{\frac{X_1}{n}}(t)\right)^n = \left(\varphi_{X_1}\left(\frac{t}{n}\right)\right)^n = \\ &\left(\mathbb{E}[e^{\frac{itX_1}{n}}]\right)^n = \left(1 + \frac{it}{n}\mathbb{E}X_1 + o\left(\frac{t}{n}\right)\right)^n. \end{aligned}$$

Pro $n \rightarrow \infty$ dále máme

$$\lim_{n \rightarrow \infty} \varphi_{\bar{X}_n}(t) = \lim_{n \rightarrow \infty} \left(1 + \frac{it}{n}\mathbb{E}X_1 + o\left(\frac{t}{n}\right)\right)^n = \lim_{n \rightarrow \infty} (\mathbb{E}[e^{it\mathbb{E}X_1/n}])^n =$$

$$\lim_{n \rightarrow \infty} (e^{it\mathbb{E}X_1/n})^n = e^{it\mathbb{E}X_1} = \varphi_{\mathbb{E}X_1}(t).$$

Z Lévyho věty (Věta 5.10) tedy dostáváme konvergenci $\bar{X}_n \xrightarrow{D} \mathbb{E}X_1$ v distribuci. Dále využijeme faktu, že jestliže posloupnost konverguje v distribuci ke konstantě, potom máme i konvergenci v pravděpodobnosti, čímž je důkaz ukončen. \square

Jestliže konvergenci v pravděpodobnosti nahradíme konvergencí skoro jistě, dostaneme silný zákon velkých čísel. Jeho důkaz je však nad rámec tohoto kurzu. Kdybychom předpokládali, že $\text{Var } X_1 < \infty$, pak tvrzení plyne okamžitě z Čebyševovy nerovnosti (Věta 4.3).

Věta 5.15 (Centrální limitní věta). *Pokud $\{X_n\}_{n \in \mathbb{N}}$ je posloupnost IID náhodných veličin s $\mathbb{E}X_1^2 < \infty$ a $\text{Var } X_1 > 0$, pak*

$$Z_n := \sqrt{n} \frac{\bar{X}_n - \mathbb{E}X_1}{\sqrt{\text{Var } X_1}} \xrightarrow{D} Z \sim N(0, 1).$$

Jinými slovy, pro všechna $x \in \mathbb{R}$,

$$\lim_{n \rightarrow \infty} P[Z_n \leq x] = \Phi(x) \equiv \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt.$$

Zkráceně tedy máme $Z_n \xrightarrow[n \rightarrow \infty]{D} N(0, 1)$.

Důkaz. Tentokrát budeme potřebovat rozvoj exponenciály do druhého řádu. Je tedy $e^{ity} = 1 + ity + \frac{(ity)^2}{2} + o(t^2)$. Potom také $\mathbb{E}[e^{itY}] = 1 + it\mathbb{E}Y - \frac{t^2}{2}\mathbb{E}Y^2 + o(t^2)$.

Definujme $Y_n := \frac{(\bar{X}_n - \mathbb{E}X_1)}{\sqrt{\text{Var } X_1}}$. Pak $\mathbb{E}Y_n = 0$, $\text{Var } Y_n = 1$ a platí

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n Y_i = \sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n Y_i \right) = \sqrt{n} \bar{Y}_n = \sqrt{n} \frac{\bar{X}_n - \mathbb{E}X_1}{\sqrt{\text{Var } X_1}} =: Z_n$$

pro každé $n \in \mathbb{N}$. Dále můžeme počítat

$$\begin{aligned} \varphi_{Z_n}(t) &= \varphi_{\sum_{i=1}^n \frac{1}{\sqrt{n}} Y_i}(t) = \left(\varphi_{\frac{Y_1}{\sqrt{n}}}(t) \right)^n = \left(\varphi_{Y_1} \frac{t}{\sqrt{n}} \right)^n = \\ &= \left(1 + \frac{it}{\sqrt{n}} \mathbb{E}Y_1 - \frac{t^2}{2n} \mathbb{E}Y_1^2 + o\left(\frac{t^2}{n}\right) \right)^n = \left(1 - \frac{t^2}{2n} + o\left(\frac{t^2}{n}\right) \right)^n, \end{aligned}$$

neboť $\mathbb{E}Y_1 = 0$ a $\mathbb{E}Y_1^2 = \text{Var } Y_1 = 1$. Jelikož $e^y = \lim_{n \rightarrow \infty} (1 + \frac{y}{n})^n$, dostáváme

$$\lim_{n \rightarrow \infty} \varphi_{Z_n}^t = \lim_{n \rightarrow \infty} \left(1 - \frac{t^2}{2n} \right)^n = e^{-\frac{1}{2}t^2} = \varphi_Z(t),$$

kde $Z \sim N(0, 1)$. Z Lévyho věty (Věta 5.10) je konvergence charakteristických funkcí ekvivalentní konvergenci v distribuci, čímž je důkaz ukončen. \square

Následující věta nám umožní zformulovat mnohorozměrnou verzi centrální limitní věty.

Věta 5.16 (Cramér-Woldova věta). *Platí $\vec{X}_n \xrightarrow{D} X$ právě tehdy, když pro všechna $\vec{t} \in \mathbb{R}^d$ platí $\vec{t}^T \vec{X}_n \xrightarrow{D} \vec{t}^T \vec{X}$.*

Důkaz. Důkaz plyne okamžitě z Věty 5.10 a spojitosti lineárních zobrazení. \square

Věta 5.17 (Mnohorozměrná CLT). *Pokud $\{\vec{X}_n\}_{n \in \mathbb{N}}$ je IID posloupnost rozměrných náhodných vektorů s pozitivně definitní varianční-kovarianční maticí $\text{Var } \vec{X}_1$, pak*

$$\sqrt{n}(\bar{\vec{X}}_n - \mathbb{E}\vec{X}_1) \xrightarrow{D} N_d(\vec{0}, \text{Var } \vec{X}_1), n \rightarrow \infty.$$

Věta 5.18 (Delta metoda). *Pokud $\sqrt{n}(Y_n - \mu) \xrightarrow{D} N(0, \sigma^2)$ a g je spojiteře diferencovatelná v okolí μ taková, že $g'(\mu) \neq 0$, pak*

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

Důkaz. Podle věty o střední hodnotě dostáváme $g(Y_n) = g(\mu) + g'(\tilde{\mu})(Y_n - \mu)$, kde $\tilde{\mu}$ leží mezi Y_n a μ . Když $\sqrt{n}(Y_n - \mu) \xrightarrow{D} N(0, \sigma^2)$, potom $Y_n - \mu \xrightarrow{D} 0$. Pak tedy i $Y_n - \mu \xrightarrow{P} 0$. Jelikož $|\tilde{\mu} - \mu| \leq |Y_n - \mu|$, musí platit, že $\tilde{\mu} - \mu \xrightarrow{P} 0$. Dle věty o spojitém zobrazení (Věta 5.7) dostáváme $g'(\tilde{\mu}) \xrightarrow{P} g'(\mu)$ (předpokládáme spojitost g').

Dále můžeme dosadit $\sqrt{n}[g(Y_n) - g(\mu)] = g'(\tilde{\mu})\sqrt{n}(Y_n - \mu)$. Nakonec, ze Slutského věty (Věta 5.8) máme (využili jsme předpoklad, že $\sqrt{n}(Y_n - \mu) \xrightarrow{D} N(0, \sigma^2)$)

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

\square

Obdobně se dá zformulovat i mnohorozměrná delta-metoda (za předpokladu nenulovosti jakobiánu g).

konec 14. přednášky (1.4.2025)

6 Statistické učení

V této kapitole se budeme věnovat základům matematické statistiky, což je obor, který bude středobodem naší pozornosti po celý zbytek semestru. Začneme formalizací pojmu týkajícího se opakováního provádění experimentu a charakterizací statistických modelů.

Definice 6.1. Pokud jsou X_1, \dots, X_n nezávislé a každá má stejné marginální rozdělení a distribuční funkci F , říkáme, že X_1, \dots, X_n jsou IID (nezávislé a stejně rozdělené) a píšeme

$$X_1, \dots, X_n \stackrel{IID}{\sim} F.$$

Takové X_1, \dots, X_n nazýváme *náhodný výběr* velikosti n z F .

Obecně si představujeme měřitelná zobrazení X_1, \dots, X_n . V praxi však většinou dostaneme pouze reálná čísla $X_i(\omega)$ pro jedno konkrétní $\omega \in \Omega$. Možná rozdělení těchto náhodných veličin budeme modelovat pomocí takzvaných parametrických modelů, tedy množin \mathcal{F} rozdělení, jež se dají parametrizovat konečným počtem parametrů.

Příklad 6.2 (Normální model).

$$\mathcal{F} = \left\{ f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}, \mu \in \mathbb{R}, \sigma^2 > 0 \right\}.$$

Taková data pochází z normálního rozdělení se dvěma parametry μ a σ^2 .

Všechny parametrické modely můžeme obecně zapsat ve tvaru

$$\mathcal{F} = \{f(\cdot; \vec{\theta}) : \vec{\theta} \in \vec{\Theta} \subseteq \mathbb{R}^d\}.$$

V dalším textu budeme využívat následující značení:

$$P_\theta[X \in A] := \int_A f(x; \theta) dx;$$

$$\mathbb{E}_\theta[g(X)] := \int_{\mathbb{R}} g(x) f(x; \theta) dx.$$

Velkou skupinou modelů jsou také neparametrické modely, které nemůžeme parametrizovat konečným počtem parametrů. Například, celou funkci hustoty můžeme považovat za nekonečnědimenzionální prostor. Uvedeme si jeden příklad takového neparametrického modelu.

Příklad 6.3 (Model Sobolevova prostoru).

$$\mathcal{F} = \left\{ f : \int_{\mathbb{R}} (f''(x))^2 dx < \infty \right\}.$$

Data pochází z rozdělení s nepříliš „vlnitou“ hustotou.

Definice 6.4. Bodový odhad $\hat{\theta}_n$ parametru θ je měřitelná funkce t náhodných veličin X_1, \dots, X_n :

$$\hat{\theta}_n = t(X_1, \dots, X_n).$$

V této definici předpokládáme, že θ je pevné ale neznámé reálné číslo (vektor). Avšak získaný odhad $\hat{\theta}_n$ je sice náhodná veličina, ale umíme ji přesně charakterizovat.

Definice 6.5. Odhad $\hat{\theta}_n$ je *nestranný*, pokud $\mathbb{E}[\hat{\theta}_n] = \theta$ pro všechna $n \in \mathbb{N}$. *Vychýlení* odhadu definujeme jako $\text{bias}(\hat{\theta}_n) := \mathbb{E}[\hat{\theta}_n] - \theta$. Odhad je *konzistentní*, jestliže $\hat{\theta}_n \xrightarrow{P} \theta$ pro $n \rightarrow \infty$.

V dnešní době je díky vývoji výpočetní techniky nestrannost více upozadována, větší důraz proto klademe na konzistenci modelu.

Definice 6.6. Rozdělení odhadu $\hat{\theta}_n$ nazýváme *výběrové rozdělení*. Standardní odchylku $\hat{\theta}_n$ nazýváme *standardní chyba* se $\text{se}(\hat{\theta}_n) = \sqrt{\text{Var } \hat{\theta}_n}$.

V těchto případech je standardní chyba se neznámá veličina (parametr), ale obvykle ji můžeme odhadnout. Takovou odhadnutou standardní chybu značíme $\widehat{\text{se}}$.

Příklad 6.7. Mějme Bernoulliho náhodný výběr $X_1, \dots, X_n \stackrel{IID}{\sim} Be(p)$ a parametr $p \in (0, 1)$. Potom můžeme uvažovat odhad

$$\hat{p}_n := \frac{1}{n} \sum_{i=1}^n X_i$$

a z toho získáme odhad standardní chyby (díky nezávislosti a stejné rozdělenosti máme $\text{Var}(\hat{p}_n) = \frac{p(1-p)}{n}$). Jelikož přesná hodnota p je neznámá, musíme tento parametr také odhadnout, proto

$$\widehat{\text{se}}(\hat{p}_n) := \sqrt{\frac{\hat{p}_n(1 - \hat{p}_n)}{n}}.$$

Definice 6.8. Kvalitu bodového odhadu můžeme posuzovat pomocí *střední kvadratické chyby*

$$\text{MSE}(\hat{\theta}_n) := \mathbb{E}_{\theta}[\hat{\theta}_n - \theta]^2.$$

Mějme na paměti, že \mathbb{E}_{θ} se v případě nezávislých a stejně rozdělených X_i vztahuje k očekávané hodnotě vzhledem k rozdělení

$$f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta).$$

Věta 6.9 (Rozklad střední kvadratické chyby). *Mějme odhad $\hat{\theta}_n$. Pak vždy platí $\text{MSE}(\hat{\theta}_n) = \text{bias}^2(\hat{\theta}_n) + \text{Var}(\hat{\theta}_n)$.*

Důkaz. Rozepsáním definice dostáváme

$$\begin{aligned}\text{MSE}[\hat{\theta}_n] &= \mathbb{E}_{\theta}[\hat{\theta}_n - \theta]^2 = \mathbb{E}_{\theta} \left\{ [\hat{\theta}_n - \mathbb{E}\hat{\theta}_n + \mathbb{E}\hat{\theta}_n - \theta]^2 \right\} = \\ &= \mathbb{E}_{\theta} \left\{ [\hat{\theta}_n - \mathbb{E}\hat{\theta}_n]^2 - 2[\hat{\theta}_n - \mathbb{E}\hat{\theta}_n][\mathbb{E}\hat{\theta}_n - \theta] + [\mathbb{E}\hat{\theta}_n - \theta]^2 \right\} = \\ &= \text{Var}(\hat{\theta}_n) + \text{bias}^2(\hat{\theta}_n),\end{aligned}$$

kde poslední rovnost plyne z toho, že druhý sčítanec je nulový, což plyne z linearity střední hodnoty. \square

Věta 6.10 (Postačující podmínka pro konzistenci). *Nechť platí $\text{bias}(\hat{\theta}_n) \rightarrow 0$ a $\text{Var}(\hat{\theta}_n) \rightarrow 0$. Potom platí $\hat{\theta}_n$ je konzistentní.*

Důkaz. Z Věty 6.9 dostáváme, že $\text{MSE}(\hat{\theta}_n) = \mathbb{E}_{\theta}[\hat{\theta}_n - \theta]^2 \rightarrow 0$. Z definice L_2 konvergence dostáváme, že $\hat{\theta}_n \xrightarrow{L_2} \theta$. Zbytek dostáváme z faktu, že L_2 konvergence implikuje konvergenci v pravděpodobnosti. \square

Příklad 6.11. Mějme stejnou situaci jako v Příkladu 6.7. Jelikož náš odhad je nestranný ($\mathbb{E}(\hat{p}_n) = p$) a $\text{Var}(\hat{p}_n) = \frac{p(1-p)}{n} \rightarrow 0$ pro $n \rightarrow \infty$, dostáváme díky Větě 6.10, že $\hat{p}_n \xrightarrow{P} p$.

Definice 6.12. Odhad $\hat{\theta}_n$ parametru θ se nazývá *asymptoticky standardně normální*, jestliže pro $n \rightarrow \infty$ platí

$$\frac{\hat{\theta}_n - \theta}{\text{se}(\hat{\theta}_n)} \xrightarrow{D} N(0, 1).$$

Definice 6.13. $(1-\alpha)$ -interval spolehlivosti (konfidenční interval) pro parametr θ je interval $C_n = (a, b)$, kde $a = a(X_1, \dots, X_n)$ a $b = b(X_1, \dots, X_n)$ jsou měřitelné funkce dat takové, že pro všechna $\theta \in \Theta$

$$P_{\theta}[\theta \in C_n] = 1 - \alpha.$$

Asymptotický (přibližný) $(1-\alpha)$ -interval spolehlivosti pro parametr θ je interval C_n takový, že pro všechna $\theta \in \Theta$

$$\lim_{n \rightarrow \infty} P_{\theta}[\theta \in C_n] = 1 - \alpha.$$

Tato definice říká, že interval C_n zachytí θ s pravděpodobností (přibližně) $1 - \alpha$. Tento parametr nazýváme *pokrytí* intervalu spolehlivosti (CI). Interval spolehlivosti je náhodná veličina, i přestože θ je pevné deterministické. Pro vícerozměrné prostory uvažujeme kouli/elipsoid spolehlivosti (ale toto rozšíření je komplikovanější, protože na \mathbb{R}^d , $d > 1$ neexistuje vhodné uspořádání).

konec 15. přednášky (8.4.2025)

Příklad 6.14 (Interval spolehlivosti a normalita). Mějme stejný setup jako v Příkladu 6.2, tedy $X_1, \dots, X_n \stackrel{IID}{\sim} N(\mu, \sigma^2)$ a parametr $\mu \in \mathbb{R}$ je neznámý a má být odhadnut (bodový odhad a konfidenční interval), $\sigma^2 > 0$ je předpokládáno známé.

Nezávislost a stejná rozdělenost nám poskytuje možnost pracovat s mnohorozměrným vektorem $\vec{X} := (X_1, \dots, X_n)^T \sim ((\mu, \dots, \mu)^T, \sigma^2 I_n)$.

Uvažujme bodový odhad $\hat{\mu}_n = \frac{1}{n} \sum_{i=1}^n X_i \equiv \bar{X}_n$. Tento odhad je konsistentní, což plyne ze zákona velkých čísel 5.14. Z linearity normálních rozdělení dostaváme $\sqrt{n}(\hat{\mu}_n - \mu)/\sigma \sim N(0, 1)$.

Nechť $u_\beta := \Phi^{-1}(\beta)$ je β -kvantil ($\beta \in (0, 1)$) standardního normálního rozdělení a nechť $Y = \sqrt{n} \frac{\bar{X}_n - \mu}{\sigma}$. Potom

$$\begin{aligned} P[-u_{1-\alpha/2} \leq Y \leq u_{1-\alpha/2}] &= P[Y \leq u_{1-\alpha/2}] - P[Y \leq -u_{1-\alpha/2}] = \\ &1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha \end{aligned}$$

pro všechna $n \in \mathbb{N}$ a $\mu \in \mathbb{R}$. Ve druhé rovnosti jsme použili vlastnost $u_\beta = -u_{1-\beta}$, která se snadno ověří přímým dosazením do definice distribuční funkce normálního rozdělení.

Jednoduchými algebraickými úpravami získáme nerovnost pro μ (zapíšeme to rovnou ve tvaru intervalu):

$$\mu \in \left(\bar{X}_n - u_{1-\alpha/2} \sqrt{\frac{\sigma^2}{n}}, \bar{X}_n + u_{1-\alpha/2} \sqrt{\frac{\sigma^2}{n}} \right).$$

Tento interval je $1 - \alpha$ interval spolehlivosti pro hodnotu μ . Tedy s pravděpodobnosti $1 - \alpha$ leží hodnota μ v tomto intervalu.

Pro výpočet také můžeme použít centrální limitní větu, v tomto případě dostaneme stejný interval spolehlivosti (s poznámkou, že jde o přibližný, tedy asymptotický interval spolehlivosti).

Zkoumejme délku získaného intervalu spolehlivosti. Z předchozího příkladu máme délku $2u_{1-\alpha/2} \sqrt{\frac{\sigma^2}{n}}$. Poznamenejme si, že s klesajícím α (povolená tolerance) roste délka intervalu. Taktéž roste délka intervalu s rostoucím rozptylem σ^2 a klesajícím rozsahem výběru n . Mějme danou délku d . Kolik pozorování potřebujeme, aby chom získali interval spolehlivosti užší než d ? Vychází

$$n \geq \left\lceil \frac{4u_{1-\alpha/2}^2 \sigma^2}{d^2} \right\rceil + 1.$$

Věta 6.15 (Interval spolehlivosti založený na normalitě). *Předpokládejme, že $\hat{\theta}_n$ je asymptoticky standardně normální odhad parametru θ a $\text{se}(\hat{\theta}_n)$ je konsistentní odhad $\text{se}(\theta_n)$, tj. $\text{se}(\hat{\theta}_n) - \text{se}(\hat{\theta}_n) \xrightarrow{P} 0$. Nechť $u_{1-\alpha/2}$ je $(1 - \alpha/2)$ -kvantil standardního normálního rozdělení a*

$$C_n = \left(\hat{\theta}_n - u_{1-\alpha/2} \text{se}(\hat{\theta}_n), \hat{\theta}_n + u_{1-\alpha/2} \text{se}(\hat{\theta}_n) \right).$$

Pak

$$P_\theta[\theta \in C_n] \xrightarrow{n \rightarrow \infty} 1 - \alpha.$$

Důkaz. Z definice asymptoticky standardně normálního odhadu máme

$$\frac{\hat{\theta}_n - \theta}{\text{se}(\hat{\theta}_n)} \xrightarrow{D} N(0, 1)$$

a máme konzistentní odhad standardní chyby odhadu

$$\widehat{\text{se}}(\hat{\theta}_n H) - \text{se}(\hat{\theta}_n) \xrightarrow{P} 0.$$

Ze Slutského věty (Věta 5.8) dostáváme $Y := \frac{\hat{\theta}_n - \theta}{\widehat{\text{se}}(\hat{\theta}_n)} \xrightarrow{D} N(0, 1)$. Potom již platí

$$\lim_{n \rightarrow \infty} P[-u_{1-\alpha/2} \leq Y \leq u_{1-\alpha/2}] = \Phi(u_{1-\alpha/2}) - \Phi(-u_{1-\alpha/2}) = 1 - \alpha.$$

□

Neformálně zapisujeme $\hat{\theta}_n \approx N(\theta, \widehat{\text{se}}(\hat{\theta}_n))$. Přibližně platí pro 95%-intervaly spolehlivosti $\alpha = 0.05$ a $u_{0.975} \approx 1.96 \approx 2$ vedoucí k explicitnímu intervalu spolehlivosti $\hat{\theta}_n \pm 2\widehat{\text{se}}(\hat{\theta}_n)$.

Příklad 6.16. Pokračujeme v Příkladu 6.11. Již jsme spočítali $\hat{p}_n \xrightarrow{P} p$, $\text{se}(\hat{p}_n) = \sqrt{p(1-p)/n}$ a $\widehat{\text{se}}(\hat{p}_n) := \sqrt{\hat{p}_n(1-\hat{p}_n)/n}$. Ze Slutského věty pak máme $\widehat{\text{se}}(\hat{p}_n) - \text{se}(\hat{p}_n) \xrightarrow{P} 0$.

Z centrální limitní věty dostáváme, že $\frac{\hat{p}_n - p}{\text{se}(\hat{p}_n)} \xrightarrow{D} N(0, 1)$. Dále opětovným použitím Slutského věty získáme $\frac{\hat{p}_n - p}{\widehat{\text{se}}(\hat{p}_n)} \xrightarrow{D} N(0, 1)$. Tedy z předchozí věty

$$\hat{p}_n \pm u_{1-\alpha/2} \sqrt{\hat{p}_n(1-\hat{p}_n)/n}$$

je asymptotický (přibližný) $(1 - \alpha)$ -interval spolehlivosti pro p .

7 Statistické funkcionály

Nechť X_1, \dots, X_n je IID náhodný výběr z F s rozsahem výběru n . Chceme odhadnout F jejím empirickým protějškem.

Definice 7.1 (ECDF). Pro $x \in \mathbb{R}$ definujeme

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \chi_{\{X_i \leq x\}}.$$

Takto definovaná empirická distribuční funkce splňuje všechny vlastnosti normální distribuční funkci a přiřazuje váhu $\frac{1}{n}$ každému pozorování X_i . Také ECDF můžeme definovat jako relativní četnost X menších nebo rovných pevnému x , to znamená $\frac{1}{n} |\{X_i \leq x\}|$.

konec 16. přednášky (14.4.2025)

Věta 7.2 (Bodové vlastnosti ECDF). Pro libovolné pevné $x \in \mathbb{R}$,

- (i) $\mathbb{E} [\hat{F}_n(x)] = F(x);$
- (ii) $\text{Var} [\hat{F}_n(x)] = \frac{F(x)(1-F(x))}{n};$
- (iii) $\text{MSE} (\hat{F}_n(x)) = \frac{F(x)(1-F(x))}{n} \rightarrow 0 \text{ pro } n \rightarrow \infty;$
- (iv) $\hat{F}_n(X) \xrightarrow{P} F(x) \text{ pro } n \rightarrow \infty.$

Důkaz. Platí $\mathbb{E} [\hat{F}_n(x)] = \mathbb{E} [\frac{1}{n} \sum_{i=1}^n \chi_{\{X_i \leq x\}}] = \frac{1}{n} \sum_{i=1}^n P[X_i \leq x] = F(x).$
Tím jsme dokázali první vlastnost.

Dále platí $\text{Var} [\hat{F}_n(x)] = \text{Var} [\frac{1}{n} \sum_{i=1}^n \chi_{\{X_i \leq x\}}] = \frac{1}{n^2} \sum_{i=1}^n \text{Var} [\chi_{\{X_i \leq x\}}] = \frac{1}{n^2} \sum_{i=1}^n [\mathbb{E} \chi^2 - (\mathbb{E} \chi)^2] = \frac{1}{n^2} \sum_{i=1}^n (F(x) - F(x)^2) = \frac{F(x)(1-F(x))}{n}$, čímž jsme dokázali druhou vlastnost.

K důkazu třetí rovnosti si uvědomíme, že díky již dokázané vlastnosti (i) je $\text{bias}(\hat{F}_n(x)) = 0$ a tedy $\text{MSE} (\hat{F}_n(x)) = \text{Var} [\hat{F}_n(x)].$

Nakonec, díky zákonu velkých čísel (Věta 5.14) máme

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \chi_{\{X_i \leq x\}} \xrightarrow{P} \mathbb{E} [\chi_{\{X_1 \leq x\}}] = F(x).$$

□

Definice 7.3. *Funkcionál* je zobrazení $T : \mathcal{F} \rightarrow \mathbb{R}$, kde \mathcal{F} je nějaká množina funkcí.

Definice 7.4. *Statistický funkcionál* je zobrazení T , které přiřadí rozdělení P_X reálné číslo.

Můžeme také definovat vektorové funkcionály, stačí obor hodnot nahradit \mathbb{R}^d . Uvedeme si několik příkladů statistických funkcionálů.

Příklad 7.5. Následující operátory jsou statistické funkcionály:

- střední hodnota $\mu = \mathbb{E}X = \int x dP_X(x)$;
- rozptyl $\sigma^2 = \text{Var } X = \int (x - \mu)^2 dP_X(x)$;
- medián $F^{-1}(1/2) \equiv \inf\{x : P_X((-\infty, x]) > 1/2\}$.

Definice 7.6. Pokud $T(P_X) = \int r(x)dP_X(x)$ pro nějakou měřitelnou funkci r , pak T nazýváme *lineární statistický funkcionál*.

Motivací této definice je fakt, že takto definovaný funkcionál T je lineární ve svých argumentech, jinými slovy,

$$T(aP_X + bP_Y + c) = aT(P_X) + bT(P_Y) + c$$

pro $a, b, c \in \mathbb{R}$.

Z předchozího příkladu dostaneme, že střední hodnota a rozptyl jsou lineární a medián není (neexistuje vhodná měřitelná funkce r).

Definice 7.7. Nechť X_1, \dots, X_n je náhodný výběr z F s rozsahem výběru n , kde $X_i : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$ pro $i = 1, \dots, n$. Pak

$$\hat{P}_n(B) := \frac{1}{n} \sum_{i=1}^n \chi_{\{X_i \in B\}} \equiv \frac{1}{n} \sum_{i=1}^n \delta_{X_i}(B)$$

pro $B \in \mathcal{B}(\mathbb{R})$ se nazývá *empirická pravděpodobnostní míra*.

Právě definovaný objekt je *náhodná pravděpodobnostní míra*, které má diskrétní rovnoměrné pravděpodobnostní rozdělení (součet Diracových mér) na náhodných bodech X_1, \dots, X_n , kde každý tento bod má váhu $\frac{1}{n}$.

Definice 7.8. *Plug-in odhad* neznámého parametru $\theta = T(P_X)$ je $\hat{\theta}_n := T(\hat{P}_n)$.

Myslenkou definice plug-in odhadu je nahrazení neznámé pravděpodobnostní míry jejím odhadem.

Příklad 7.9. Platí $\hat{F}_n(x) = \hat{P}_n((-\infty, x])$ pro $x \in \mathbb{R}$.

Definice 7.10. *Empirický (plug-in) odhad* pro lineární statistický funkcionál $T(P_X) = \int r(x)dP_X(x)$ je

$$T(\hat{P}_n) = \int r(x)d\hat{P}_n(x).$$

Věta 7.11 (Výpočet plug-in odhadu pro lineární statistický funkcionál). *Pro empirický odhad lineárního statistického funkcionálu $T(P_X) = \int r(x)dP_X(x)$ platí*

$$T(\hat{P}_n) = \frac{1}{n} \sum_{i=1}^n r(X_i).$$

Důkaz. Nechť $\omega \in \Omega$ je dáno. Z definice empirického odhadu lineárního statistického funkcionálu dostáváme

$$\begin{aligned} T(\hat{P}_n)(\omega) &= \int_{\mathbb{R}} r(x) d\hat{P}_n(\omega)(x) = \int_{\mathbb{R}} r(x) d\left(\frac{1}{n} \sum_{i=1}^n \delta_{X_i(\omega)}(x)\right) = \\ &= \frac{1}{n} \sum_{i=1}^n \int_{\mathbb{R}} r(x) d\delta_{X_i(\omega)}(x) = \frac{1}{n} \sum_{i=1}^n r(X_i(\omega)). \end{aligned}$$

□

Příklad 7.12. Spočteme empirickou střední hodnotu. Máme $\mu = T(P_X) = \int x dP_X(x)$ a tedy díky předchozí větě

$$\hat{\mu}_n = \int x d\hat{P}_n(x) = \bar{X}_n.$$

Příklad 7.13. Spočteme empirický rozptyl. Z definice rozptylu máme

$$\text{Var } X = \sigma^2 = T(P_X) = \int (x - \mu)^2 dP_X(x) = \int x^2 dP_X(x) - \left(\int x dP_X(x)\right)^2.$$

Potom

$$\begin{aligned} \hat{\sigma}_n^2 &= \int x^2 d\hat{P}_n(x) - \left(\int x d\hat{P}_n(x)\right)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2. \end{aligned}$$

Příklad 7.14. Spočteme empirickou korelacii. Nechť tedy $Z = [X, Y]^T$ a nechť $\rho = T(P_{[X,Y]^T})$ označuje příslušnou korelacii. Můžeme psát

$$T(P_{[X,Y]^T}) = a(T_1(P_{[X,Y]^T}), T_2(P_{[X,Y]^T}), T_3(P_{[X,Y]^T}), T_4(P_{[X,Y]^T}), T_5(P_{[X,Y]^T})),$$

kde

$$\begin{aligned} T_1(P_{[X,Y]^T}) &= \int x dP_{[X,Y]^T}(x, y), \\ T_2(P_{[X,Y]^T}) &= \int y dP_{[X,Y]^T}(x, y), \\ T_3(P_{[X,Y]^T}) &= \int xy dP_{[X,Y]^T}(x, y), \\ T_4(P_{[X,Y]^T}) &= \int x^2 dP_{[X,Y]^T}(x, y), \\ T_5(P_{[X,Y]^T}) &= \int y^2 dP_{[X,Y]^T}(x, y) \end{aligned}$$

a zároveň $a(t_1, t_2, t_3, t_4, t_5) = \frac{t_3 - t_1 t_2}{\sqrt{(t_4 - t_1^2)(t_5 - t_2^2)}}$. Dosazením se snadno ověří, že tímto jsme opravdu získali vzorec pro daný funkcionál. Nahrazením distribuční funkce jejím empirickým protějškem nakonec dostáváme

$$\hat{\rho} = \frac{\sum_i (X_i - \bar{X}_n)(Y_i - \bar{Y}_n)}{\sqrt{\sum_i (X_i - \bar{X}_n)^2 \sum_j (Y_j - \bar{Y}_n)^2}}.$$

Tuto veličinu nazýváme *výběrovou korelací*.

Definice 7.15. Připomínka: pro $p \in (0, 1)$ definujeme *p-tý kvantil* jako $T(F) = F^{-1}(p) = \inf\{x : F(x) > p\}$.

Nyní definujeme

$$T(\hat{F}_n) = \hat{F}_n^{-1}(p) = \inf\{x : \hat{F}_n(x) > p\}$$

a tento objekt nazýváme *p-tý výběrový kvantil*. Obdobně definujeme *výběrový medián* jako $\hat{F}_n^{-1}(1/2)$. Navíc mezikvartilové rozpětí $\tilde{T}(F) = F^{-1}(3/4) - F^{-1}(1/4)$ lze odhadnout pomocí *výběrového mezikvartilového rozpětí* $\tilde{T}(\hat{F}_n) = \hat{F}_n^{-1}(3/4) - \hat{F}_n^{-1}(1/4)$.

8 Parametrická inference

V této kapitole se budeme věnovat problému odhadování parametru tak, aby získané rozdělení co nejvhodněji pasovalo na experimentální data. Hlavním objektem zkoumání bude rodina parametrických modelů

$$\mathcal{F} := \{f(\cdot, \vec{\theta}) : \vec{\theta} \in \vec{\Theta} \subseteq \mathbb{R}^d\},$$

kde $\vec{\Theta}$ je parametrický prostor a $\vec{\theta} = (\theta_1, \dots, \theta_d)$ je parametr.

Je zřejmé, že ne každý model je schopen pokrýt všechna možná rozdělení vyskytující se v přírodě. Musíme proto approximovat a umět dobré odhadnout, kdy máme "dost dobrý" odhad. Budeme se zajímat o odhad nějaké funkce $T(\vec{\theta})$. Například pro $X_i \sim N(\mu, \sigma^2)$, pokud naším parametrem zájmu je μ , stačí volit $T(\vec{\theta}) = \mu$ a σ^2 se potom nazývá *nežádoucí/rušivý parametr*.

Příklad 8.1. Připomeňme si, že náhodná veličina X má rozdělení $\Gamma(a, p)$, jestliže

$$f_X(x; a, p) = \frac{a^p}{\Gamma(p)} x^{p-1} \exp\{-ax\}.$$

kde $a, p > 0$ a

$$\Gamma(p) = \int_0^\infty y^{p-1} e^{-y} dy.$$

Parametrem ve smyslu úvodu je tedy vektor $\vec{\theta} = (a, p)$. Chceme-li spočítat průměrnou délku života (což je jedna z věcí, k modelování kterých se používá Gamma rozdělení), dostáváme

$$T(a, p) = \mathbb{E}_{\vec{\theta}} X = \int_0^\infty \frac{a^p x^p}{\Gamma(p)} e^{-ax} dx = \frac{1}{a\Gamma(p)} \int_0^\infty y^p e^{-y} dy = \frac{\Gamma(p+1)}{a\Gamma(p)} = \frac{p}{a}.$$

V dalším textu uvažujme náhodný výběr $X_1, \dots, X_n \stackrel{IID}{\sim} F \in \mathcal{F}$.

Příklad 8.2. Uvažujme $\mathcal{F} = \{F(\mu) : \mathbb{E}_{F(\mu)} = \mu \wedge |\mu| < \infty\}$ rodinu modelů s konečnou střední hodnotou. Potom \bar{X}_n je konzistentní a nestranný odhad μ a X_1 je nestranný, ale ne konzistentní odhad μ .

Dále uvažujme $\mathcal{F} = \{F(\sigma^2) : \text{Var}_{F(\sigma^2)} = \sigma^2 < \infty\}$ rodinu modelů s konečným rozptylem. Potom $\hat{\sigma}_n^2 = n^{-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ je konzistentní, ale ne nestranný odhad σ^2 a $S_n^2 = (n-1)^{-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ je konzistentní a nestranný odhad σ^2 .

konec 17. přednášky (15.4.2025)

Příklad 8.3. Necht $\mathcal{F} = \{Po(\lambda), \lambda > 0\}$ a $\theta = P[X_i = 0] = e^{-\lambda}$. Potom $\hat{\theta}_n = n^{-1} \sum_{i=1}^n \chi_{\{X_i=0\}}$ (relativní četnost nul v původních datech) je konzistentní a nestranný odhad λ . Zároveň také $\tilde{\theta}_n = \left(\frac{n-1}{n}\right)^{\sum_{i=1}^n X_i}$ je konzistentní a nestranný.

Ukážeme si, že $\hat{\theta}_n$ je nestranný. Chceme dokázat, že $\mathbb{E}\hat{\theta}_n = \theta$. Můžeme psát

$$\mathbb{E}\hat{\theta}_n = \mathbb{E} \left[\frac{1}{n} \sum_{i=1}^n \chi_{\{X_i=0\}} \right] = \frac{1}{n} \sum_{i=1}^n P[X_i = 0] = \theta.$$

Obdobně ukážeme konzistenci tohoto odhadu, tedy, že $\hat{\theta}_n \rightarrow \theta$. Díky slabému zákonu velkých čísel (Věta 5.14):

$$\hat{\theta}_n \xrightarrow{P} \mathbb{E}[\chi_{\{X_1=0\}}] = P[X_1 = 0] = \theta.$$

Dále pro odhad $\tilde{\theta}_n$ můžeme psát (používáme označení $\sum_{i=1}^n X_i = Y$)

$$\begin{aligned} \mathbb{E}\tilde{\theta}_n &= \mathbb{E} \left(\frac{n-1}{n} \right)^{\sum_{i=1}^n X_i} = \sum_{y=1}^{\infty} \left(\frac{n-1}{n} \right)^y \frac{(n\lambda)^y}{y!} e^{-n\lambda} = \\ &e^{-n\lambda} \sum_{y=0}^{\infty} \frac{[(n-1)\lambda]^y}{y!} = e^{-\lambda}, \end{aligned}$$

kde první rovnost plyne z toho, že součet n IID poissonovských náhodných veličin s parametrem λ je opět poissonovská náhodná veličina s parametrem $n\lambda$. K důkazu konzistence zlogaritmujeme náš odhad, dostaneme

$$\log \tilde{\theta}_n = \left(\sum_{i=1}^n X_i \right) \log \frac{n-1}{n} = \bar{X}_n \log \left(1 - \frac{1}{n} \right)^n \xrightarrow{P} -\lambda.$$

Limitní přechod jsme získali díky Slutského větě (Věta 5.8). Dále z věty o spojité transformaci (Věta 5.7) aplikované na funkci $t(x) = e^x$ dostáváme, že $\tilde{\theta}_n \xrightarrow{P} \theta$.

Ve speciálním případě $\theta = e^{-2\lambda}$ jediný nestranný odhad je $(-1)^{\bar{X}_n}$, který ale nikdy nedosáhne přípustné hodnoty $e^{-2\lambda}$.

Skutečně, necht existuje nestranný odhad parametru $\theta \in (0, 1)$. Označme ho $\hat{\theta}_n = T(X_1, \dots, X_n)$. Z definice nestrannosti musí platit, že $\mathbb{E}T(X_1, \dots, X_n) = \theta$. Potom platí

$$\theta = \mathbb{E} \sum_{x=0}^{\infty} T(x) \frac{\lambda^x}{x!} e^{-\lambda} \stackrel{\text{předpoklad}}{=} e^{-2\lambda}.$$

Z toho však plyne, že

$$\sum_{x=0}^{\infty} T(x) \frac{\lambda^x}{x!} = e^{-\lambda} = \sum_{x=0}^{\infty} \frac{(-\lambda)^x}{x!},$$

a tedy $T(x) = (-1)^x$ (rovnost mocninných řad).

Dále se budeme věnovat takzvané momentové metodě. Jedná se o univerzální techniku získání odhadů, která však ale nemusí poskytnout ten nejlepší možný odhad. Často ji například využijeme jako startovací bod pro další iterativní numerické metody.

Definice 8.4. Definujeme k -tý necentrální moment jako

$$\mu'_k \equiv \mu'_k(\vec{\theta}) = \mathbb{E}_{\vec{\theta}} X^k = \int x^k f_X(x, \vec{\theta}) dP_X$$

a k -tý výběrový moment jako

$$\hat{\mu}'_k = \frac{1}{n} \sum_{i=1}^n X_i^k.$$

Definice 8.5. Odhad metodou momentů $\hat{\vec{\theta}}_n$ je definován jako hodnota $\vec{\theta}$, pro kterou platí

$$\mu'_1(\hat{\vec{\theta}}_n) = \hat{\mu}'_1, \dots, \mu'_d(\hat{\vec{\theta}}_n) = \hat{\mu}'_d.$$

Alternativně bychom mohli použít centrované k -té momenty spolu s jejich empirickými protějšky.

Příklad 8.6. Nechť $X_1, \dots, X_n \stackrel{IID}{\sim} Be(p)$. Pak $\mu'_1 = \mathbb{E}_p X_1 = p$ a $\hat{\mu}'_1 = \bar{X}_n$. Rovnost těchto dvou hodnot nám dává odhad

$$\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n$$

a je to opět stejný plug-in odhad.

Příklad 8.7. Nechť $X_1, \dots, X_n \stackrel{IID}{\sim} N(\mu, \sigma^2)$. Pak $\mu'_1 = \mathbb{E}_{(\mu, \sigma^2)} X_1 = \mu$ a $\mu'_2 = \mathbb{E}_{(\mu, \sigma^2)} X_1^2 = \text{Var}_{(\mu, \sigma^2)} X_1 + (\mathbb{E}_{(\mu, \sigma^2)} X_1)^2 = \sigma^2 + \mu^2$. Musíme vyřešit soustavu rovnic

$$\begin{aligned} \hat{\mu}_n &= \frac{1}{n} \sum_{i=1}^n X_i; \\ \hat{\mu}_n^2 + \hat{\sigma}_n^2 &= \frac{1}{n} \sum_{i=1}^n X_i^2. \end{aligned}$$

Řešením této soustavy je $\hat{\mu}_n = \bar{X}_n$ a $\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$.

Je důležité si poznamenat, že někdy si nevystačíme s prvními d momenty, například, pokud je naše teoretické rozdělení symetrické okolo nuly.

Příklad 8.8. Nechť $X_1, \dots, X_n \stackrel{IID}{\sim} \Gamma(a, p)$, kde

$$f_X(x; a, p) = \frac{a^p}{\Gamma(p)} x^{p-1} e^{-ax}, x > 0,$$

kde $a, p > 0$ a $\Gamma(p) = \int_0^\infty y^{p-1} e^{-y} dy$ je Gamma funkce. Pak, odhadu momentovou metodou

$$\hat{a}_n = \frac{\bar{X}_n}{\hat{\sigma}_n^2} \quad \text{a} \quad \hat{p}_n = \frac{\bar{X}_n^2}{\hat{\sigma}_n^2}$$

jsou konzistentní a AN.

Skutečně, máme

$$\begin{aligned}\mu'_1(a, p) &= \mathbb{E}_{(a, p)} X_1 = \frac{p}{a}, \\ \mu'_2(a, p) &= \mathbb{E}_{(a, p)} X_1^2 = \int_0^\infty x^2 \frac{a^p}{\Gamma(p)} x^{p-1} e^{-ax} = \frac{a^p \Gamma(p+2)}{\Gamma(p) a^{p+2}} = \frac{(p+1)p}{a^2}.\end{aligned}$$

Stačí tedy vyřešit soustavu

$$\begin{aligned}\hat{\mu}'_1 &= \frac{1}{n} \sum_{i=1}^n X_i = \mu'_1(\hat{a}, \hat{p}) = \frac{\hat{p}}{\hat{a}}; \\ \hat{\mu}'_2 &= \frac{1}{n} \sum_{i=1}^n X_i^2 = \mu'_2(\hat{a}, \hat{p}) = \frac{(\hat{p}+1)\hat{p}}{\hat{a}^2};\end{aligned}$$

Jejím řešením jsou právě výše uvedené odhady.

konec 18. přednášky (22.4.2025)

A Ukázková zápočtová písemka – Varianta A

Příklad A.1. V šesti urnách máme v každé 10 míčků. V jedné urně je osm černých, ve dvou urnách je po pěti černých a ve třech urnách je po k černých. Zbylé míčky jsou bílé.

- (a) Nechť $k = 3$. Z náhodně vybrané urny jsem s vracením vytáhli dva míčky, oba bílé. S jakou pravděpodobností bylo v urně pět černých míčků?

Nechť V_5 je událost, že byla vybrána urna s i bílými míčky, H je událost, že oba vytažené míčky jsou bílé. Z Bayesovy věty (Věta 1.15) máme, že $P(V_5|H) = P(H|V_5) \frac{P(V_5)}{P(H)}$. Dále máme, že $P(H|V_5) = \left(\frac{1}{2}\right)^2 = \frac{1}{4}$ a $P(V_5) = \frac{2}{6} = \frac{1}{3}$. Nakonec spočteme

$$P(H) = \sum_i P(H|V_i)P(V_i) = \frac{1}{6} \cdot \left(\frac{1}{5}\right)^2 + \frac{2}{6} \cdot \left(\frac{1}{2}\right)^2 + \frac{3}{6} \cdot \left(\frac{7}{10}\right)^2 = \frac{67}{200}.$$

Dosazením do výše uvedeného vzorce dostáváme $P(V_5|H) = \frac{1}{4} \cdot \frac{1}{3} \cdot \frac{200}{67} = \frac{50}{201}$.

- (b) Kolik musí být k , aby pravděpodobnost vytažení černého míčku z náhodně vybrané urny byla $\frac{1}{2}$.

Využijeme větu o úplné pravděpodobnosti (Věta 1.14). Nechť B, W jsou jevy, že jsme vytáhli černý/bílý míček a A_i reprezentuje jev, že byla vybrána i-tá urna. Platí

$$\begin{aligned} \frac{1}{2} = P[B] &= \sum_{i=1}^n P[B|A_i]P[A_i] = \underbrace{P[B|A_1]A_1}_{\frac{8}{10} \cdot \frac{1}{6} = \frac{2}{15}} + \underbrace{2 \cdot P[B|A_2]A_2}_{2 \cdot \frac{5}{10} \cdot \frac{1}{6} = \frac{1}{6}} + \\ &\quad \underbrace{3 \cdot P[B|A_4]P[A_4]}_{3 \cdot \frac{k}{10} \cdot \frac{1}{6} = \frac{k}{20}} = \frac{2}{15} + \frac{1}{6} + \frac{k}{20} = \frac{6+k}{20}. \end{aligned}$$

Vyřešením této lineární rovnice dostáváme, že $k = 4$.

- (c) Nechť $k = 2$. Náhodně vybereme jednu urnu, kterou vynecháme, ze zbylých náhodně vytáhneme po jednom míčku. Jaká je pravděpodobnost, že všechny vytažené míčky jsou bílé?

Nechť V_i je událost, že byla vyřazena i-tá urna. Potom nechť W_i je událost, že byl vytažen bílý míček z i-té urny. Jevy W_i jsou navzájem nezávislé a zároveň jsou nezávislé jevy W_j a V_i pro $i \neq j$. Označme hledanou pravděpodobnost P , můžeme psát

$$\begin{aligned} P &= \sum_{i=1}^6 P(V_i) \left(\prod_{j \neq i} P(W_j) \right) = \underbrace{\frac{1}{6} \left(\left(\frac{5}{10}\right)^2 \cdot \left(\frac{8}{10}\right)^3 \right)}_{\frac{8}{375}} + \\ &\quad \underbrace{\frac{2}{6} \left(\frac{2}{10} \cdot \frac{5}{10} \cdot \left(\frac{8}{10}\right)^3 \right)}_{\frac{32}{1875}} + \underbrace{\frac{3}{6} \left(\frac{2}{10} \cdot \left(\frac{5}{10}\right)^2 \cdot \left(\frac{8}{10}\right)^2 \right)}_{\frac{2}{125}} = \frac{34}{625}. \end{aligned}$$

Příklad A.2. Náhodná veličina Y má spojité rozdělení s hustotou

$$f_Y(y) = \begin{cases} 3e^{-3y}, & y \geq 0; \\ 0, & \text{jinak.} \end{cases}$$

Definujeme $U := \lceil Y \rceil$ a $V := \lceil Y \rceil - Y$ (tedy horní celou a frakcionální část Y).

- (a) Určete rozdělení náhodné veličiny U .

Zřejmě půjde o diskrétní rozdělení, kde pro $u \geq 1$ budeme mít

$$P[U = u] = P[u - 1 < Y < u] = \int_{u-1}^u 3e^{-3y} dy = e^{-3(u-1)}(e^{3(u-1)} - 1).$$

- (b) Určete rozdělení náhodné veličiny V .

Tentokrát půjde o spojité rozdělení, spočteme jeho distribuční funkci. Pro $v \in (0, 1)$ máme

$$F_V(v) = P[V < v] = \sum_{t=1}^{\infty} \int_{t-v}^t 3e^{-3y} dy = \sum_{t=1}^{\infty} e^{-3(t-v)}(e^{3(t-v)} - 1) = \frac{e^{3v} - 1}{e^3 - 1}.$$

Pro $v \leq 0$ je F_V nulová, pro $v \geq 1$ máme $F_V(v) = 1$.

- (c) Spočtěte $\mathbb{E}(Ye^{-Y} - 1)$.

Využijeme pravidlo líného statistika (Věta 3.5) s transformací $t(y) = ye^{-y}$, dostaneme

$$\mathbb{E}(Ye^{-Y}) = \int_0^\infty (ye^{-y} \cdot 3e^{-3y}) = \int_0^\infty 3ye^{-4y} = \frac{3}{16}.$$

S využitím linearity střední hodnoty dostaneme $\mathbb{E}(Ye^{-Y} - 1) = \mathbb{E}(Ye^{-Y}) - 1 = -\frac{13}{16}$.

Příklad A.3. Náhodný vektor $(X, Y)^T$ má spojité rozdělení s hustotou

$$f(x, y) = \begin{cases} ay, & -1 < x < -1, 0 < y \leq x^2; \\ 0, & \text{jinak,} \end{cases}$$

kde $a \in \mathbb{R}$ je vhodná konstanta.

- (a) Určete $a \in \mathbb{R}$.

Platí, že integrál hustoty přes celý prostor je roven 1. Můžeme tedy psát

$$1 = \int_{-1}^1 \int_0^{x^2} ay dy dx = \frac{a}{5}.$$

Tedy $a = 5$.

- (b) Určete marginální rozdělení a střední hodnotu náhodné veličiny X .
Platí pro $|x| < 1$ (jinde je hustota nulová)

$$f_X(x) = \int_{\mathbb{R}} f(x, y) dy = \int_0^{x^2} 5y dy = \frac{5x^4}{2},$$

dále spočteme

$$\mathbb{E}[X] = \int_{-1}^1 x f_X(x) dx = \int_{-1}^1 \frac{5x^5}{2} = 0.$$

- (c) Určete $P(0 < X < \sqrt{2Y})$.

Nalezneme průsečík grafů funkcí $y = x^2$ a $x = \sqrt{2y}$. Máme $y = x^2 = \frac{1}{2}x^2$, tedy grafy těchto funkcí se protnou pouze počátku a jinde je hodnota druhé funkce ostře menší než hodnota první. Požadovaná podmínka je splněna pro hodnoty $(x, y) \in \mathbb{R}^2$, které se nachází mezi těmito dvěma parabolami. Můžeme tedy integrovat

$$P(0 < X < \sqrt{2Y}) = \int_0^1 \int_{\frac{1}{2}x^2}^{x^2} 5y dy dx = \frac{3}{8}.$$

- (d) Spočtěte kovarianci veličin X a Z , kde $Z = XY$. Dle známého vzorce máme $\text{Cov}(X, XY) = \mathbb{E}(X \cdot XY) - \mathbb{E}X \mathbb{E}XY = \mathbb{E}[X^2 Y] - \mathbb{E}X \mathbb{E}XY$. Opět s využitím pravidla líného statistika můžeme integrovat

$$\text{Cov}(X, XY) = \int_{-1}^1 \int_0^{x^2} x^2 y \cdot 5y dy dx = \frac{10}{27}.$$

- (e) Rozhodněte, zda jsou veličiny X a Y nezávislé a své rozhodnutí zdůvodněte.
Náhodné veličiny X a Y nejsou nezávislé, neboť

$$0 = P[0 < x < \frac{1}{2}, y > \frac{1}{4}] \neq P[0 < x < \frac{1}{2}] P[y > \frac{1}{4}],$$

jelikož zjevně ani jeden z činitelů na pravé straně není nulový.

B Ukázková zápočtová písemka – Varianta B

Příklad B.1. Máme šest truhel a v každé z nich je jedna stříbrná mince. Do jedné truhly vložíme tři zlaté mince, do dvou truhel dvě zlaté mince a do zbylých tří truhel po jedné zlaté minci (dohromady jsme tak dodali deset zlatých mincí).

- (a) Z náhodně vybrané truhly dvakrát táhneme s vrácením. Jaká je pravděpodobnost, že vytáhneme jednu zlatou a jednu stříbrnou minci.
Nechť H je událost, že jsme vytáhli jednu zlatou a jednu stříbrnou minci z dané truhly a V_i jsou události, že jsme náhodně vybrali i -tou truhlu. Potom $P(H) = 2 \frac{p-1}{p} \cdot \frac{1}{p}$ (p je počet mincí v dané truhle, chceme jednu zlatou

a jednu stříbrnou a nezáleží na pořadí) a $P(V_i) = \frac{1}{6}$. Potom ze zákona úplné pravděpodobnosti dostáváme

$$P(H) = \sum_{i=1}^6 P(V_i)P(H|V_i) = \frac{1}{6} \cdot 2 \cdot \frac{1}{4} \cdot \frac{3}{4} + \frac{2}{6} \cdot 2 \cdot \frac{1}{3} \cdot \frac{2}{3} + \frac{3}{6} \cdot 2 \cdot \frac{1}{2} \cdot \frac{1}{2} = \\ \frac{1}{16} + \frac{4}{27} + \frac{1}{4} = \frac{199}{432}.$$

- (b) Z náhodně vybrané truhly jsme dvakrát tálili s vracením a vytáhli jednu zlato a jednu stříbrnou minci (bez ohledu na pořadí). S jakou pravděpodobností to byla truhla s alespoň dvěma zlatými mincemi?

Z Bayesovy věty (Věta 1.15) máme (použijeme stejnou notaci jako v předchozím příkladu) $P(V_i|H) = P(H|V_i) \frac{P(V_i)}{P(H)}$. Chceme spočítat

$$\sum_{i=1}^3 P(V_i|H) = \sum_{i=1}^3 P(H|V_i) \frac{P(V_i)}{P(H)} = \frac{1}{P(H)} (P(H|V_1)P(V_1) + \\ 2P(H|V_2)P(V_2)) = \frac{432}{199} \left(2 \cdot \frac{1}{4} \cdot \frac{3}{4} \cdot \frac{1}{6} + 2 \cdot 2 \cdot \frac{1}{3} \cdot \frac{2}{3} \cdot \frac{1}{6} \right) = \frac{91}{199}.$$

- (c) Náhodně vybereme tři truhly a z každé náhodně vytáhneme po jedné minci. S jakou pravděpodobností bude alespoň jedna z nich zlatá?

Spočteme nejdříve pravděpodobnost opačného jevu, tedy události, že budou vytaženy tři stříbrné mince. Označme $V_{(i,j,k)}$ pravděpodobnost, že bylo náhodně zvoleno i truhel se třemi zlatými mincemi, j truhel se dvěma a k truhel s jednou zlatou mincí. Pravděpodobnost tohoto jevu se spočte pomocí vzorce

$$P(V_{(i,j,k)}) = \frac{\binom{1}{i} \binom{2}{j} \binom{3}{k}}{\binom{6}{3}} = \frac{\binom{2}{j} \binom{3}{k}}{20}.$$

Dále označme S jev, že byly vytaženy 3 stříbrné mince. Potom

$$P(S) = \sum_{i,j,k} P(V_{(i,j,k)}) \frac{1}{4^i} \cdot \frac{1}{3^j} \cdot \frac{1}{2^k}.$$

Možné hodnoty i, j, k a příslušné pravděpodobnosti $P(V_{(i,j,k)})$ zapíšeme do tabulky.

i	j	k	$P(V_{(i,j,k)})$	sčítanec v $P(S)$
1	2	0	1/20	1/720
1	1	1	6/20	1/80
1	0	2	3/20	3/320
0	0	3	1/20	1/160
0	2	1	3/20	1/120
0	1	2	6/20	1/40

Potom $P(S) = \frac{181}{2880}$ a tedy hledaná pravděpodobnost vytažení alespoň jedné zlaté mince je $P(S^C) = 1 - P(S) = \frac{2699}{2880}$.

Příklad B.2. Náhodná veličina X má spojité rozdělení s hustotou

$$f(x) = \begin{cases} 2e^{-2x}, & x \geq 0; \\ 0, & \text{jinak.} \end{cases}$$

Definujme $U := \lfloor X \rfloor$ a $V := X - \lfloor X \rfloor$ (jinými slovy spodní celá část a frakcionální část X).

(a) Určete rozdělení náhodné veličiny U .

Jedná se o diskrétní náhodnou veličinu s pravděpodobnostní funkci

$$P[U = u] = \int_u^{u+1} f(x)dx = [-e^{-2x}]_u^{u+1} = e^{-2u}(1 - e^{-2})$$

pro $u \geq 0$.

(b) Určete rozdělení náhodné veličiny V .

Tentokrát máme spojitou náhodnou veličinu, spočteme její distribuční funkci.
Nechť $v \in (0, 1)$, potom

$$\begin{aligned} F_V(v) &= P[V \leq v] = \sum_{u=0}^{\infty} \int_0^v f(u+t)dt = \sum_{u=0}^{\infty} \int_0^v 2e^{-2u}e^{-2t}dt = \\ &\sum_{u=0}^{\infty} e^{-2u}(1 - e^{-2v}) = \frac{1 - e^{-2v}}{1 - e^{-2}}. \end{aligned}$$

Pro $v \leq 0$ máme $F_V(v) = 0$, pro $v \geq 1$ máme $F_V(v) = 1$.

(c) Spočtěte $\mathbb{E}(Xe^{-X} - 1)$.

S využitím pravidla líného statistika (Věta 3.5) dostáváme (transformace $t(x) = xe^{-x} - 1$)

$$\mathbb{E}t(X) = \int_0^{\infty} t(x)f(x)dx = \int_0^{\infty} (xe^{-x} - 1)2e^{-2x}dx = \frac{2}{9} - 1 = -\frac{7}{9}.$$

Příklad B.3. Náhodný vektor $(X, Y)^T$ má spojité rozdělení s hustotou

$$f(x, y) = \begin{cases} 2x, & 0 < x < 1, -x^2 < y < x^2; \\ 0, & \text{jinak.} \end{cases}$$

(a) Určete $P(0 < 2Y < X^2)$.

Počítáme obsah útvaru mezi osou x a křivkou $y = \frac{1}{2}x^2$ s hustotou $f(x, y)$.
Máme integrál

$$\int_0^1 \int_0^{\frac{1}{2}x^2} 2xy dx dy = \int_0^1 x^3 dx = \frac{1}{4}.$$

- (b) Určete marginální rozdělení a střední hodnotu veličiny X .

Hustotu f_X získáme zintegrováním hustoty $f(x, y)$ přes všechny možné hodnoty y , tedy

$$f_X(x) = \int_{-x^2}^{x^2} 2xdy = 4x^3.$$

Dále platí

$$\mathbb{E}X = \int_0^1 xf_X(x)dx = \int_0^1 4x^4 dx = \frac{4}{5}.$$

- (c) Spočtěte kovarianci veličin X a W , kde $W = X^2Y$.

Platí, že $\text{Cov}(X, X^2Y) = E[X^3Y] - E[X]E[X^2Y]$, tedy potřebujeme dopočítat chybějící střední hodnoty

$$E[X^3Y] = \int_0^1 \int_{-x^2}^{x^2} x^3 y \cdot 2xdydx = 0;$$

$$E[X^2Y] = \int_0^1 \int_{-x^2}^{x^2} x^2 y \cdot 2xdydx = 0,$$

(v obou případech je integrand lichý v proměnné y , a tedy integrál přes interval $[-a, a]$ je roven nule). Vychází $\text{Cov}(X, X^2Y) = 0 - 0 = 0$.

- (d) Rozhodněte, zda jsou veličiny X a Y nezávislé a své rozhodnutí zdůvodněte.

Veličiny X a Y nejsou nezávislé, neboť $P[0 < X < \frac{1}{2}, Y > \frac{1}{4}] = 0 \neq P[0 < X < \frac{1}{2}]P[Y > \frac{1}{4}]$ (součin zřejmě nenulových hodnot).