


8. cvičení z PST

9. listopadu 2022

Poznámky k normálnímu rozdělení:

Veličina X má *normální* (neboli Gaussovo) rozdělení $N(\mu, \sigma^2)$ (kde $\mu \in \mathbb{R}$ a $\sigma > 0$), jestliže má hustotu

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad \text{pro } x \in \mathbb{R}.$$



Je to tedy spojité rozdělení, $E(X) = \mu$, $\text{var}(X) = \sigma^2$ a oborem hodnot veličiny X je celá reálná osa. Všimněme si ještě, že hustota f_X je symetrická vzhledem ke středu μ a proto platí $F_X(\mu) = \frac{1}{2}$.

Toto rozdělení je limitním rozdělením, které aproximuje součty nezávislých stejně (nebo podobně) rozdělených veličin (více později v Centrální limitní větě). Typicky se tedy objevuje u veličin, jejichž hodnoty jsou ovlivněny mnoha drobnými odchylkami (např. u chyb měření, výšky člověka apod.)

Značení: Pro náhodnou veličinu X s konečnou střední hodnotou a konečným rozptylem, položeme

$$\text{norm}(X) := \frac{X - E(X)}{\sqrt{\text{var}(X)}}.$$

Speciálně tedy vidíme, že $E(\text{norm}(X)) = 0$ a $\text{var}(\text{norm}(X)) = 1$.

Platí: Pro takovou veličinu X a konstanty $a > 0$ a $b \in \mathbb{R}$ je

$$\text{norm}(aX + b) = \text{norm}(X).$$

Důležité vlastnosti normálního rozdělení:

- $X \sim N(\mu, \sigma^2) \Rightarrow \text{norm}(X) = \frac{X-\mu}{\sigma} \sim N(0, 1)$ (je to tzv. normované normální rozdělení s hodnotami v tabulkách dist. funkce pro $N(0, 1)$ se značí Φ).

V tomto případě pak máme $F_X(t) = P(X \leq t) = P\left(\underbrace{\frac{X-\mu}{\sigma}}_{=\text{norm}(X)} \leq \frac{t-\mu}{\sigma}\right) = \Phi\left(\frac{t-\mu}{\sigma}\right)$ pro všechna $t \in \mathbb{R}$.

- hustota $f_{N(0,1)}$ je sudá funkce $\Rightarrow \Phi(t) + \Phi(-t) = 1$ pro všechna $t \in \mathbb{R}$.
- Nechtě $X_i \sim N(\mu_i, \sigma_i^2)$, pro $i = 1, 2$, jsou nezávislé. Pak $X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$ (tj. speciálně součet nezávislých normálních rozdělení je zase normální.)

Pro vybraná čísla $t \geq 0$ se dají hodnoty Φ najít ve statistických tabulkách. Pro záporná čísla si pak pomůžeme vztahem $\Phi(-t) = 1 - \Phi(t)$.

Pro lepší představu o tom, jakou roli pro veličinu s normálním rozdělením $X \sim N(\mu, \sigma^2)$ hraje směrodatná odchylka σ se používá tzv.

pravidlo tří-sigma (https://cs.wikipedia.org/wiki/Pravidlo_t%C5%99%C3%AD_sigma)

keré je ovšem čistě jen technickou pomůckou:

Jestliže si budeme počítat pravděpodobnosti

$$P(|X - \mu| \leq k \cdot \sigma) = P\left(\underbrace{\left|\frac{X - \mu}{\sigma}\right|}_{\sim N(0,1)} \leq k\right) = \Phi(k) - \Phi(-k) = 2 \cdot \Phi(k) - 1 \quad \text{pro } k = 1, 2, 3, \dots$$


dostaneme postupně

$$P(|X - \mu| \leq \sigma) = 2 \cdot \Phi(1) - 1 \doteq 2 \cdot 0.8413 - 1 = 0.6826 \doteq 68\%$$

$$P(|X - \mu| \leq 2 \cdot \sigma) = 2 \cdot \Phi(2) - 1 \doteq 2 \cdot 0.9772 - 1 = 0.9544 \doteq 95\%$$

$$P(|X - \mu| \leq 3 \cdot \sigma) = 2 \cdot \Phi(3) - 1 \doteq 2 \cdot 0.99865 - 1 = 0.9973 \doteq 99.7\%$$

Pro vyšší hodnoty, tj. $k \geq 4$ už jsou pravděpodobnosti v podstatě rovny 1, takže se v praxi příliš nepoužívají (záleží samozřejmě na zvolené přesnosti).



Příklad 8.1 Výška dětí v 1. třídě je náhodná veličina $X \sim N(130 \text{ cm}, 36 \text{ cm}^2)$. Jaká je pravděpodobnost, že náhodně vybrané dítě bude


- (a) větší než 136 cm,
- (b) menší než 118 cm,
- (c) mít výšku mezi 127 a 133 cm?

Řešení:

Nyní tedy máme $X \sim N(130, 36)$. Pro jednodušší zápis si ještě označme $Z := \text{norm}(X)$.


(a)

$$\begin{aligned} P(X > 136) &= P\left(\underbrace{\frac{X - 130}{\sqrt{36}}}_Z > \underbrace{\frac{136 - 130}{\sqrt{36}}}_1\right) = P(Z > 1) = 1 - P(Z \leq 1) = \\ &= 1 - \Phi(1) \doteq 1 - 0.8413 = 0.1587. \end{aligned}$$




(b)

$$\begin{aligned}
 P(X < 118) &= P\left(\frac{X - 130}{\sqrt{36}} < \frac{118 - 130}{\sqrt{36}}\right) = P(Z < -2) = \Phi(-2) = \\
 &= 1 - \Phi(2) \doteq 1 - 0.9772 = 0.0228 .
 \end{aligned}$$



(c)

$$\begin{aligned}
 P(127 < X < 133) &= P\left(\frac{127 - 130}{\sqrt{36}} < \frac{X - 130}{\sqrt{36}} < \frac{133 - 130}{\sqrt{36}}\right) = \\
 &= P(-0.5 < Z < 0.5) = P(Z < 0.5) - P(Z \leq -0.5) = \\
 &= \Phi(0.5) - \Phi(-0.5) = \Phi(0.5) - (1 - \Phi(0.5)) = \\
 &= 2 \cdot \Phi(0.5) - 1 \doteq 2 \cdot 0.6915 - 1 = 0.383 .
 \end{aligned}$$



Poznamenejme ještě, že hodnoty výšek, které nás zajímaly (tj. 136 cm, 118 cm atd.) se pohybují celkem blízko střední hodnoty $E(X) = 130$ cm, takže předpoklad o normálnosti rozdělení X byl přiměřený.

Výpočty si můžeme i urychlit přímým vzorcem $F_X(t) = \Phi\left(\frac{t-\mu}{\sigma}\right)$, kde $\mu = 130$ cm a $\sigma = 6$ cm:

$$(a) P(X > 136) = 1 - F_X(136) = 1 - \Phi\left(\frac{136-130}{6}\right) = \dots \doteq 0.1587$$

$$(b) P(X < 118) = F_X(118) = \Phi\left(\frac{118-130}{6}\right) = \dots \doteq 0.0228$$

$$(c) P(127 < X < 133) = F_X(133) - F_X(127) = \Phi\left(\frac{133-130}{6}\right) - \Phi\left(\frac{127-130}{6}\right) = \dots \doteq 0.383$$

Příklad 8.2 *Oštěpařky Anna a Barbora mají střední hodnoty hodů po řadě 67 m a 75 m a směrodatné odchylky 6 m a 3 m. Předpokládejme nezávislá normální rozdělení. Odhadněte pravděpodobnost, že při jednom hodu hodí Anna dál.*

Řešení:

Náhodná veličina

A = “délka hodu Anny”

má rozdělení $N(67, 6^2)$ a veličina

B = “délka hodu Barbory”

má rozdělení $N(75, 3^2)$.

Zajímá nás $P(A > B) = P(A - B > 0)$. Protože veličiny A a B jsou nezávislé, tak veličina $Z := A - B$ má také normální rozdělení, a sice

$$Z \sim N(67 - 75, 6^2 + 3^2) = N(-8, 45).$$

Takže

$$\begin{aligned} P(A > B) &= P(Z > 0) = P\left(\underbrace{\frac{Z - (-8)}{\sqrt{45}}}_{\text{norm}(Z)} > \frac{0 - (-8)}{\sqrt{45}}\right) = 1 - P\left(\text{norm}(Z) \leq \frac{8}{\sqrt{45}}\right) = \\ &= 1 - \Phi\left(\frac{8}{\sqrt{45}}\right) \doteq 1 - \Phi(1.1926) \doteq 1 - 0.883 = 0.117. \end{aligned}$$

POZOR! Zatímco střední hodnota je lineární zobrazení, tak rozptyl se chová jinak! Konkrétně je to takto:

Nechť X a Y jsou veličiny se střední hodnotou a konečným rozptylem. Pak

- $E(X \pm Y) = E(X) \pm E(Y)$
- $\text{var}(X \pm Y) = \text{var}(X) + \text{var}(Y) \pm 2 \cdot \text{cov}(X, Y) (\geq 0)$

Zde $\text{cov}(X, Y)$ je tzv. kovariance (viz poznámky níže). Speciálně, pokud X a Y jsou nezávislé, je $\text{cov}(X, Y) = 0$. Máme tedy:

- X a Y nezávislé $\Rightarrow \text{var}(X \pm Y) = \text{var}(X) + \text{var}(Y)$

Tedy v tomto případě se rozptyly VŽDY sčítají!

Připomenutí: Jestliže máme dvě náhodné veličiny $X, Y : \Omega \rightarrow \mathbb{R}$, pak zobrazení

$$(X, Y) : \Omega \rightarrow \mathbb{R}^2$$

nazýváme **náhodný (dvousložkový) vektor**.

Tedy náhodnému výsledku ω (tj. elementárnímu jevu) přiřadíme dvojici hodnot $(x, y) \in \mathbb{R}^2$. Např. vybranému člověku z množiny lidí Ω přiřadíme jeho tělesnou výšku a hmotnost.

(Obdobně vznikne náhodný vektor s více složkami. My se teď zaměříme hlavně na dvousložkový případ.)

Náhodný vektor (X, Y) umí přenést a vytvořit rozdělení pravděpodobnosti na \mathbb{R}^2 - a to tak, že každá "rozumná" množina $A \subseteq \mathbb{R}^2$ (např. otevřená množina nebo interval atd.) bude mít prostě pravděpodobnost

$$P_{(X,Y)}(A) := P\left(\underbrace{(X, Y)^{-1}(A)}_{\{\omega \in \Omega \mid (X(\omega), Y(\omega)) \in A\}}\right).$$

Rozdělení této pravděpodobnosti $P_{(X,Y)}$ na \mathbb{R}^2 můžeme opět úplně popsat, pokud známe pravděpodobnosti jen některých speciálních intervalů a ty nám definují tzv. **sduženou distribuční funkci** $F_{(X,Y)} : \mathbb{R}^2 \rightarrow \langle 0, 1 \rangle$ jako

$$F_{(X,Y)}(a, b) := P(X \leq a, Y \leq b)$$

Je dobré si uvědomit, že náhodný vektor (X, Y) můžeme snadno sestavit z libovolných dvou náhodných veličin X a Y . Zatímco ale k počítání s veličinou X nám stačí znát jen její distribuční funkci F_X , k práci s vektorem nám NESTAČÍ znalost distribučních funkcí jeho složek! Potřebujeme totiž znát, jaký je vztah mezi veličinami X a Y , a ten je schovaný právě ve sdužené distribuční funkci.

Opět si připomeňme, že pojem nezávislosti pro jevy umožňuje přirozeně definovat nezávislost veličin :

Definice: Veličiny X a Y jsou **nezávislé** $\Leftrightarrow P(X \in I, Y \in J) = P(X \in I) \cdot P(Y \in J)$ pro libovolné intervaly $I, J \subseteq \mathbb{R}$.

Věta: X a Y jsou nezávislé $\Leftrightarrow F_{(X,Y)}(a, b) = F_X(a) \cdot F_Y(b)$ pro všechna $a, b \in \mathbb{R}$.

Příklad 8.3 Délka hrany krychle je náhodná veličina $X \sim \text{Ro}(1, 2)$. Určete distribuční funkci náhodné veličiny Y popisující plochu povrchu této krychle.

Řešení:

Máme veličiny

$$X = \text{"délka hrany krychle"}$$

$$Y = \text{"plocha povrchu krychle"}$$

takže $Y = 6 \cdot X^2$ a pro distribuční funkci náhodné veličiny Y dostáváme

$$F_Y(y) = P(Y \leq y) = P(6X^2 \leq y) = P(X^2 \leq \frac{y}{6}) = \begin{cases} P(|X| \leq \sqrt{\frac{y}{6}}) = F_X(\sqrt{\frac{y}{6}}) & , y \geq 0 \\ P(\emptyset) = 0 & , y < 0 . \end{cases}$$


kde jsme využili toho, že obor hodnot pro X je $\langle 1, 2 \rangle$, tedy $X \geq 0$ a speciálně tak platí, že $|X| = X$.

Teď si už si jen vyjádříme F_X a dosadíme:

Pro veličinu $X \sim \text{Ro}(1, 2)$ je její hustota $f_X(x) = \begin{cases} 1, & 1 \leq x \leq 2 \\ 0, & \text{jinak} \end{cases}$ a distribuční funkce

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} 0, & x < 1 \\ x - 1, & 1 \leq x \leq 2 \\ 1, & x > 2 \end{cases}$$

s grafem




Do F_X (správně!) dosadíme $x = \sqrt{\frac{y}{6}}$ (pro $y \geq 0$) a prepíšeme podmínky pro y :

$$1 \leq \sqrt{\frac{y}{6}} \leq 2 \Leftrightarrow 1 \leq \frac{y}{6} \leq 4 \Leftrightarrow 6 \leq y \leq 24$$

(zbylé podmínky jsou podobné) a dostaneme tak

$$F_Y(y) = \begin{cases} 0, & y < 6 \\ \sqrt{\frac{y}{6}} - 1, & 6 \leq y \leq 24 \\ 1, & y > 24 \end{cases}$$

s grafem



Připomenutí: Kovariance pro X a Y je definována jako

$$\text{cov}(X, Y) := E\left((X - EX) \cdot (Y - EY)\right) = \dots = E(XY) - E(X) \cdot E(Y) .$$

Speciálně je $\text{cov}(X, X) = \text{var}(X)$.

Kovariance $\text{cov}(\cdot, \cdot)$ má tyto vlastnosti (X, Y, Z jsou veličiny, $a, b, c, d \in \mathbb{R}$ jsou konstanty):

- je lineární v každé složce zvlášť (tj. je bilineární), tedy:

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

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

- symetrická, tj. $\text{cov}(X, Y) = \text{cov}(Y, X)$
- pozitivně semi-definitní, tj. $\text{cov}(X, X) \geq 0$, kde navíc platí, že:
 $\text{cov}(X, X) = 0 \Rightarrow \exists \alpha \in \mathbb{R}$, že $P(X = \alpha) = 1$ (neboli: X odpovídá konstantní veličině)
- $\text{cov}(X + c, Y + d) = \text{cov}(X, Y)$.

Platí: X a Y jsou nezávislé veličiny $\implies \text{cov}(X, Y) = 0$.

(POZOR: Opačná implikace obecně neplatí!!)

Příklad 8.4 Nechť $X \sim \text{Ro}(0, 2)$ a $Y = X^2 + 1$.

(a) Sestrojte distribuční funkci náhodné veličiny Y .

(b) Spočítejte $\text{cov}(X, Y)$.

(c) Rozhodněte, zda jsou X a Y nezávislé a proč.

Řešení:

- (a) Distribuční funkce F_Y se dá získat pomocí distribuční funkce F_X . Před výpočtem si ještě uvědomme, že $X \geq 0$ (protože její obor hodnot je $(0, 2)$). Speciálně tedy $|X| = X$. Pro distribuční funkci náhodné veličiny Y máme


$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(X^2 + 1 \leq y) = \\ &= P(X^2 \leq y - 1) = \begin{cases} P(\emptyset) = 0 & , y - 1 < 0 \\ P(|X| \leq \sqrt{y - 1}) = F_X(\sqrt{y - 1}) & , y - 1 \geq 0. \end{cases} \end{aligned}$$

Teď už si stačí jen vyjádřit F_X a dosadit.

Pro veličinu $X \sim \text{Ro}(0, 2)$ je její hustota $f_X(x) = \begin{cases} \frac{1}{2}, & 0 \leq x \leq 2 \\ 0, & \text{jinak} \end{cases}$ a distribuční funkce je pak

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} 0, & x < 0 \\ x/2, & 0 \leq x \leq 2 \\ 1, & x > 2 \end{cases}$$

s grafem




Do F_X (správně!) dosadíme $x = \sqrt{y-1}$ (pro $y-1 \geq 0$) a přepíšeme podmínky pro y :

$$0 \leq \sqrt{y-1} \leq 2 \Leftrightarrow 0 \leq y-1 \leq 4 \Leftrightarrow 1 \leq y \leq 5$$

(zbylé podmínky jsou podobné) a dostaneme tak

$$F_Y(y) = \begin{cases} 0, & y < 1 \\ \frac{\sqrt{y-1}}{2}, & 1 \leq y \leq 5 \\ 1, & y > 5 \end{cases}$$

s grafem



(b) Kovarianci vypočteme ze vztahu

$$\text{cov}(X, Y) = \text{cov}(X, X^2 + 1) = \text{cov}(X, X^2) = E(X \cdot X^2) - E(X) \cdot E(X^2)$$

Stačí si tedy pro $n \geq 1$ zjistit

$$E(X^n) = \int_{-\infty}^{\infty} x^n \cdot f_X(x) dx = \int_0^2 \frac{x^n}{2} dx = \left[\frac{x^{n+1}}{2(n+1)} \right]_0^2 = \frac{2^n}{n+1}$$

a dosazením dostaneme

$$\text{cov}(X, Y) = 2 - 1 \cdot \frac{4}{3} = \frac{2}{3}.$$

(c) Protože $\text{cov}(X, Y) \neq 0$, jsou veličiny X a Y závislé. Toto zjištění ovšem můžeme udělat i bez výpočtu kovariance:

Velichiny X a Y jsou funkčně propojené, takže stačí najít podmínky, které naráz nemůžou splnit, ale jednotlivě, s nenulovými pravděpodobnostmi, ano. Z předchozích úprav už víme, že pro $1 < y < 5$ platí

$$Y \leq y \Leftrightarrow X^2 + 1 \leq y \Leftrightarrow X \leq \sqrt{y-1}$$

a pravděpodobnosti těchto jevů jsou (z tvaru F_X a F_Y) ostře mezi 0 a 1. Takže např. z volby $y = 2$ dostaneme, že

$$Y \leq 2 \Leftrightarrow X \leq 1$$

takže

$$P(\underbrace{Y \leq 2, X > 1}_{\emptyset}) = 0 \neq \underbrace{P(Y \leq 2)}_{F_Y(2)=0.5} \cdot \underbrace{P(X > 1)}_{1-F_X(1)=0.5}$$

z čehož plyne, že veličiny X a Y jsou závislé.

Poznámka: Jak se dá očekávat, pokud jedna veličina závisí svými hodnotami na druhé, nejspíš nezávislé nebudou. Výjimkou je jen jeden případ a celá situaci se dá popsat takto:

Věta: Nechť X a $h(X)$ jsou obě náhodné veličiny, kde $h : \mathbb{R} \rightarrow \mathbb{R}$ je borelovská funkce (např. spojitá). Pak X a $h(X)$ jsou nezávislé veličiny právě jen pokud

- $h(X)$ je konstantní veličina (přesněji: ex. $c \in \mathbb{R}$, že $P(h(X) = c) = 1$).

Poznámky ke kovarianci a korelaci: Náhodné veličiny (jako funkce na pravděpodobnostním prostoru Ω) tvoří přirozeně (reálný) vektorový prostor (kde ještě navíc dvě veličiny budeme pokládat za totožné, pokud se rovnají s pravděpodobností 1). Na vektorovém *pod*prostoru veličin s konečnou střední hodnotou a konečným rozptylem pak můžeme přirozeným způsobem zavést skalární součin jako

$$\langle X|Y \rangle := E(X \cdot Y)$$

Díky němu můžeme přirozeně zavést *normu* $\|X\|$ (neboli "délku" vektoru X) jako

$$\|X\| := \sqrt{\langle X|X \rangle} = \sqrt{E(X^2)}.$$

Mimo jiné si všimněme, že pro X je $\text{var}(X) = \|X - E(X)\|^2$, takže platí

$$\|norm(X)\| = \left\| \frac{X - EX}{\sqrt{\text{var}(X)}} \right\| = \frac{\|X - EX\|}{\sqrt{\text{var}(X)}} = 1$$

neboli *norm*(X) má délku skutečně znormovanou na hodnotu 1.

Skalární součin nám dále umožňuje měřit také úhel mezi dvěma vektory. Pro veličiny X a Y je užitečné znát, jestli jejich výchyly vůči středním hodnotám (tj. veličiny $X - EX$ a $Y - EY$) mají podobné chování (tj. jestli korelují). Zavádíme proto korelaci mezi veličinami X a Y jako kosinus úhlu α mezi vektory $X - EX$ a $Y - EY$, tedy

$$\text{corr}(X, Y) := \frac{\langle X - EX | Y - EY \rangle}{\|X - EX\| \cdot \|Y - EY\|} = \dots = \frac{E(XY) - E(X) \cdot E(Y)}{\sqrt{\text{var}(X) \cdot \text{var}(Y)}}.$$

(Veličiny $X - EX$ a $Y - EY$ mají nulovou střední hodnotu).

A kromě toho máme:

$$\text{cov}(X, Y) := \langle X - EX | Y - EY \rangle = \dots = E(XY) - E(X) \cdot E(Y).$$

Konstantní veličina X spolu s jakoukoliv jinou veličinou Y vždy tvoří vzájemně nezávislé veličiny X a Y (tento případ je ale celkem nezájímavý).

Definice: Náhodný vektor (X, Y) má *diskrétní rozdělení* \Leftrightarrow existuje $A \subseteq \mathbb{R}^2$, která je konečná nebo spočetná a taková, že $P((X, Y) \in A) = 1$. (Tedy vektor má nejvýše spočetně mnoho "zájímavých" hodnot.)

V tomto případě pak pro *sduženou distribuční funkci* máme

$$F_{(X,Y)}(a, b) = P(X \leq a, Y \leq b) = \sum_{\substack{u \leq a \\ t \leq b}} P(X = u, Y = t).$$

Věta: Nechť náhodný vektor (X, Y) má *diskrétní* rozdělení. Pak:

X a Y jsou nezávislé $\Leftrightarrow P(X = i, Y = j) = P(X = i) \cdot P(Y = j)$ pro všechna $i, j \in \mathbb{R}$.

(Srovnajte to s obecně NEdiskrétním případem, kdy je nezávislost popsána jen nerovnostmi:

$$P(X \leq i, Y \leq j) = P(X \leq i) \cdot P(Y \leq j) \text{ pro všechna } i, j \in \mathbb{R} .)$$

Příklad 8.5 Sdružené pravděpodobnosti náhodných veličin X a Y jsou dány následující tabulkou:

	$X = 0$	$X = 1$	$X = 2$
$Y = 0$	$1/4$	$1/8$	0
$Y = 1$	$1/4$	$1/4$	$1/8$

- (a) Jaká jsou jejich marginální rozdělení? Určete pravděpodobnost $P(X + Y > 1)$.
 (b) Určete střední hodnotu $E(X \cdot Y)$. Určete varianční a korelační matici.
 (c) Jsou veličiny X a Y nezávislé? Zdůvodněte.

Řešení:

Na začátku bychom si měli pro pořádek ještě ověřit, že součet všech pravděpodobností v tabulce je $= 1$ (pokud by byl např. < 1 , pak nemáme úplnou informaci o rozdělení a nemůžeme dál pokračovat).

- (a) U veličin X a Y předpokládáme obory hodnot určené tabulkou. Pak máme

$$X + Y > 1 \Leftrightarrow (X, Y) \in \{(0, 2), (1, 1), (1, 2)\}$$

a tedy

$$P(X + Y > 1) = P\left((X, Y) \in \{(0, 2), (1, 1), (1, 2)\}\right) = \frac{1}{4} + \frac{1}{8} + 0 = \frac{3}{8} .$$

Marginální (česky: okrajová) rozdělení náhodného vektoru (X, Y) jsou rozdělení jeho jednotlivých složek, tedy veličin X a Y . Vektor (X, Y) má diskrétní rozdělení a obě veličiny X a Y budou proto mít také diskrétní rozdělení a pro jejich rozdělení platí:

$$P(X = i) = P(X = i, Y \in \mathbb{R}) = \sum_{j \in \mathbb{R}} P(X = i, Y = j)$$

$$P(Y = j) = P(X \in \mathbb{R}, Y = j) = \sum_{i \in \mathbb{R}} P(X = i, Y = j)$$

Hodnoty pravděpodobností získáme tedy sečtením v řádcích (pro X) a sloupcích (pro Y) naší tabulky:

	$X = 0$	$X = 1$	$X = 2$	$P(Y = j)$
$Y = 0$	$1/4$	$1/8$	0	$3/8$
$Y = 1$	$1/4$	$1/4$	$1/8$	$5/8$
$P(X = i)$	$1/2$	$3/8$	$1/8$	

Tedy

$$P(X = i) = \begin{cases} 1/2, & i = 0 \\ 3/8, & i = 1 \\ 1/8, & i = 2 \\ 0, & \text{jinak} \end{cases} \quad \text{a} \quad P(Y = j) = \begin{cases} 3/8, & j = 0 \\ 5/8, & j = 1 \\ 0, & \text{jinak.} \end{cases}$$

- (b) Pro diskrétní vektor (X, Y) a borelovskou (tj. téměř každou, např. spojitou) funkci $h : \mathbb{R}^2 \rightarrow \mathbb{R}$ platí podobná věc jako jsme měli už u náhodné veličiny a sice:

$$E(h(X, Y)) = \sum_{(i,j) \in \mathbb{R}^2} h(i, j) \cdot P(X = i, Y = j).$$

Odsud tedy snadno spočítáme střední hodnotu $E(XY)$:

$$\begin{aligned} E(X \cdot Y) &= \sum_{(i,j) \in \mathbb{R}^2} i \cdot j \cdot P(X = i, Y = j) = \\ &= 0 \cdot 0 \cdot \frac{1}{4} + 0 \cdot 1 \cdot \frac{1}{8} + 0 \cdot 2 \cdot 0 + 1 \cdot 0 \cdot \frac{1}{4} + 1 \cdot 1 \cdot \frac{1}{4} + 1 \cdot 2 \cdot \frac{1}{8} = \frac{1}{2} \end{aligned}$$

Kovarianci pak vypočteme ze vztahu

$$\text{cov}(X, Y) = E(XY) - E(X) \cdot E(Y)$$

K tomu potřebujeme znát také

$$\begin{aligned} E(X) &= 0 \cdot \frac{1}{2} + 1 \cdot \frac{3}{8} + 2 \cdot \frac{1}{8} = \frac{5}{8} \\ E(Y) &= 0 \cdot \frac{3}{8} + 1 \cdot \frac{5}{8} = \frac{5}{8} \end{aligned}$$

Takže

$$\text{cov}(X, Y) = E(XY) - E(X) \cdot E(Y) = \frac{1}{2} - \frac{5}{8} \cdot \frac{5}{8} = \frac{7}{64}.$$

Pro korelaci

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

potřebujeme ještě znát rozptyly, takže si je dopočítáme:

$$\begin{aligned} E(X^2) &= 0^2 \cdot \frac{1}{2} + 1^2 \cdot \frac{3}{8} + 2^2 \cdot \frac{1}{8} = \frac{7}{8}, \\ E(Y^2) &= 0^2 \cdot \frac{3}{8} + 1^2 \cdot \frac{5}{8} = \frac{5}{8}, \\ \text{var}(X) &= E(X^2) - (E(X))^2 = \frac{7}{8} - \left(\frac{5}{8}\right)^2 = \frac{31}{64}, \\ \text{var}(Y) &= E(Y^2) - (E(Y))^2 = \frac{5}{8} - \left(\frac{5}{8}\right)^2 = \frac{15}{64}. \end{aligned}$$

Všimněme si ještě, že $Y \sim \text{Alt}\left(\frac{5}{8}\right)$, takže rozptyl jsme mohli spočítat jako $\text{var}(Y) = \frac{5}{8} \cdot \left(1 - \frac{5}{8}\right) = \frac{15}{64}$.

Korelace tedy je

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X)} \cdot \sqrt{\text{var}(Y)}} = \frac{\frac{7}{64}}{\sqrt{\frac{31}{64}} \cdot \sqrt{\frac{15}{64}}} = \frac{7}{\sqrt{465}} \doteq 0.32462,$$

Varianční matice je tudíž

$$\text{Cov}(X, Y) = \begin{pmatrix} \text{cov}(X, X) & \text{cov}(X, Y) \\ \text{cov}(Y, X) & \text{cov}(Y, Y) \end{pmatrix} = \begin{pmatrix} \text{var}(X) & \text{cov}(X, Y) \\ \text{cov}(X, Y) & \text{var}(Y) \end{pmatrix} = \begin{pmatrix} \frac{31}{64} & \frac{7}{64} \\ \frac{7}{64} & \frac{15}{64} \end{pmatrix}$$

a korelační matice je

$$\text{Corr}(X, Y) = \begin{pmatrix} \text{corr}(X, X) & \text{corr}(X, Y) \\ \text{corr}(Y, X) & \text{corr}(Y, Y) \end{pmatrix} = \begin{pmatrix} 1 & \text{corr}(X, Y) \\ \text{corr}(X, Y) & 1 \end{pmatrix} = \begin{pmatrix} 1 & \frac{7}{\sqrt{465}} \\ \frac{7}{\sqrt{465}} & 1 \end{pmatrix}.$$

(c) Protože nyní je např.

$$P(X = 2, Y = 0) = 0 \neq \frac{1}{8} \cdot \frac{3}{8} = P(X = 2) \cdot P(Y = 0).$$

jsou X a Y **závislé**.

Důvodem pro závislost X a Y je také fakt, že $\text{cov}(X, Y) \neq 0$. Zdůrazníme ale, že pokud je kovariance nulová, nemůžeme (pouze na základě její znalosti) o nezávislosti obecně nic říct!

Definice: Náhodný vektor (X, Y) má spojité rozdělení se *sduženou hustotou pravděpodobnosti* $f_{X,Y} : \mathbb{R}^2 \rightarrow \langle 0, +\infty \rangle \Leftrightarrow f_{X,Y}$ je integrabilní funkce a pro každou “rozumnou” množinu $A \subseteq \mathbb{R}^2$ (tj. takovou, která se dá získat z intervalu v \mathbb{R}^2 pomocí sjednocování, průniku a doplňku) platí, že

$$P((X, Y) \in A) = \iint_A f_{X,Y}(x, y) \, dx dy .$$

To nastává právě když

$$F_{X,Y}(a, b) = \int_{-\infty}^a \int_{-\infty}^b f_{X,Y}(x, y) \, dx dy$$

pro každé $a, b \in \mathbb{R}$.

Sdužená hustota $f_{X,Y}$ opět (jako u veličin) NENÍ zdaleka určena jednoznačně, co se týče její funkční hodnoty, ale pouze hodnotami integrálů z této funkce (např. její změnou v konečně mnoha bodech nebo na nějaké hladké křivce se nezmění příslušné integrály, takže i změněná funkce bude také hustotou). Přesněji, dvě nezáporné funkce $f_{X,Y}$ a $g_{X,Y}$ (s integrálem rovným jedné) jsou hustotami pro tutéž sduženou distribuční funkci $F_{X,Y}$ právě když se rovnají *skoro všude* a zapisuje se to jako

$$f_{X,Y} = g_{X,Y} \quad (\text{s.v.}) .$$

(tj. mohou se lišit jen na takové množině $A \subseteq \mathbb{R}^2$, že $\iint_A 1 \, dx dy = 0$, tj. pokud A má nulový plošný obsah).

Příklad 8.6 *Sdužená hustota náhodných veličin X a Y je*

$$f_{(X,Y)}(x, y) = \begin{cases} \frac{1}{2}e^{-x-\frac{y}{2}}, & x > 0, y > 0, \\ 0, & \text{jinak.} \end{cases}$$

- (a) *Jaká jsou jejich marginální rozdělení?*
- (b) *Jsou veličiny X a Y nezávislé? Zdůvodněte.*
- (c) *Určete varianční a korelační matici.*

Řešení:

- (a) Marginální hustoty (tj. hustoty jednotlivých veličin X a Y) jsou

$$f_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x,y) dy = \begin{cases} \int_0^{\infty} \frac{1}{2} e^{-x-\frac{y}{2}} dy = e^{-x} \cdot [-e^{-\frac{y}{2}}]_0^{\infty} = e^{-x} & \text{pro } x > 0, \\ \int_{-\infty}^{\infty} 0 dy = 0 & \text{pro } x \leq 0. \end{cases}$$

$$f_Y(y) = \int_{-\infty}^{\infty} f_{X,Y}(x,y) dx = \begin{cases} \int_0^{\infty} \frac{1}{2} e^{-x-\frac{y}{2}} dx = \frac{1}{2} e^{-\frac{y}{2}} \cdot [-e^{-x}]_0^{\infty} = \frac{1}{2} e^{-\frac{y}{2}} & \text{pro } y > 0, \\ \int_{-\infty}^{\infty} 0 dx = 0 & \text{pro } y \leq 0. \end{cases}$$

Vidíme tedy, že obě rozdělení jsou exponenciální, konkrétně $X \sim \text{Exp}(1)$ a $Y \sim \text{Exp}(\frac{1}{2})$.

(b) Složky X a Y jsou nezávislé právě tehdy, když

$$f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y) \quad \text{pro skoro všechna } (x,y) \in \mathbb{R}^2,$$

což znamená, že množina bodů, kde uvedená rovnost neplatí má nulový plošný obsah.

(Podmínice “skoro všude” se nelze vyhnout z toho důvodu, že hustoty nejsou jednoznačně definovány svými hodnotami, ale svými integrály.)

Jak je hned vidět, v našem případě je rovnost splněna dokonce všude, takže X a Y JSOU nezávislé.

(c) Z nezávislosti X, Y plyne okamžitě $\text{cov}(X, Y) = 0$, tedy také $\text{corr}(X, Y) = 0$. Z $X \sim \text{Exp}(1)$ a $Y \sim \text{Exp}(\frac{1}{2})$ máme, že $\text{var}(X) = 1^2 = 1$ a $\text{var}(Y) = 2^2 = 4$. Tedy kovarianční matice

$$\text{Cov}(X, Y) = \begin{pmatrix} 1 & 0 \\ 0 & 4 \end{pmatrix}.$$

je a korelační matice je tak

$$\text{Corr}(X, Y) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}.$$