

# Matematika III – 9. týden

## Základní typy a vlastnosti náhodných veličin

Jan Slovák

Masarykova univerzita  
Fakulta informatiky

10.-14. 11. 2014

# Obsah přednášky

- 1 Literatura
- 2 Pravděpodobnostní funkce a hustoty
- 3 Náhodné vektory
- 4 Funkce náhodných veličin

# Plán přednášky

- 1 Literatura
- 2 Pravděpodobnostní funkce a hustoty
- 3 Náhodné vektory
- 4 Funkce náhodných veličin

## Kde je dobré číst?

- Karel Zvára, Josef Štěpán, Pravděpodobnost a matematická pravděpodobnost statistika, Matfyzpress, 2006, 230pp.
- J. Slovák, M. Panák, M. Bulant, Matematika drsně a svižně, Muni Press, Brno 2013, v+773 s., elektronická edice [www.math.muni.cz/Matematika\\_drsne\\_svizne](http://www.math.muni.cz/Matematika_drsne_svizne)
- Marie Budíková, Štěpán Mikoláš, Pavel Osecký, Teorie pravděpodobnosti a matematická statistika (sbírka příkladů), Masarykova univerzita, 3. vydání, 2004, 117 stran, ISBN 80-210-3313-4.
- Marie Budíková, Tomáš Lerch, Štěpán Mikoláš, Základní statistické metody, Masarykova univerzita, 2005, 170 stran, ISBN 80-210-3886-1.
- Riley, K.F., Hobson, M.P., Bence, S.J. Mathematical Methods for Physics and Engineering, second edition, Cambridge University Press, Cambridge 2004, ISBN 0 521 89067 5, xxiii + 1232 pp.

# Plán přednášky

- 1 Literatura
- 2 Pravděpodobnostní funkce a hustoty
- 3 Náhodné vektory
- 4 Funkce náhodných veličin

## Diskrétní náhodné veličiny

Jestliže náhodná veličina  $X$  na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  nabývá jen konečně nebo spočetně mnoha hodnot  $x_1, x_2, \dots \in \mathbb{R}$ , pak existuje **pravděpodobnostní funkce**  $f(x)$  taková, že

$$f(x) = \begin{cases} P(X = x_i) & x = x_i \\ 0 & \text{jinak.} \end{cases}$$

## Spojité náhodné veličiny

**Hustota  $f(x)$  pravděpodobnosti** pro náhodnou veličinu  $X$  je funkce splňující pro  $-\infty \leq a \leq b \leq \infty$

$$P(a < X < b) = \int_a^b f(x) dx. \quad (*)$$

Náhodná veličina  $X$ , pro kterou existuje její **hustota pravděpodobnosti** splňující (\*), se nazývá **spojitá**.

# Degenerované a alternativní rozdělení.

**Degenerované rozdělení**  $D(\mu)$  odpovídá konstantní hodnotě  $X = \mu$ . Distribuční funkce  $F_X$  a pravděpodobnostní funkce  $f_X$  jsou tedy rovny

$$F_X(t) = \begin{cases} 0 & t \leq \mu \\ 1 & t > \mu \end{cases} \quad f_X(t) = \begin{cases} 1 & t = \mu \\ 0 & \text{jinak} \end{cases} .$$

# Degenerované a alternativní rozdělení.

**Degenerované rozdělení**  $D(\mu)$  odpovídá konstantní hodnotě  $X = \mu$ . Distribuční funkce  $F_X$  a pravděpodobnostní funkce  $f_X$  jsou tedy rovny

$$F_X(t) = \begin{cases} 0 & t \leq \mu \\ 1 & t > \mu \end{cases} \quad f_X(t) = \begin{cases} 1 & t = \mu \\ 0 & \text{jinak} \end{cases}.$$

**Alternativní rozdělení**  $A(p)$  popisuje pokus s pouze dvěma možnými výsledky, kterým budeme říkat zdar a nezdar. Náhodné veličině  $X$  pro určitost přiřadíme hodnotu 0 pro nezdar a 1 pro zdar. Pokud má zdar pravděpodobnost  $p$ , pak nezdar musí mít pravděpodobnost  $1 - p$ . Jsou tedy distribuční a pravděpodobnostní funkce tvaru:

$$F_X(t) = \begin{cases} 0 & t \leq 0 \\ 1 - p & 0 < t \leq 1 \\ 1 & t > 1 \end{cases} \quad f_X(t) = \begin{cases} p & t = 1 \\ 1 - p & t = 0 \\ 0 & \text{jinak} \end{cases}.$$






# Binomické rozdělení $Bi(n, p)$

odpovídá  $n$ -krát nezávisle opakovanému pokusu popsanému alternativním rozdělením, přičemž naše náhodná veličina měří počet zdarů. Je tedy zjevné, že pravděpodobnostní funkce bude mít nenulové hodnoty právě v celých číslech  $0, \dots, n$  odpovídajícím celkovému počtu úspěchů v pokusech (a nezáleží nám na pořadí). Je tedy

$$f_X(t) = \begin{cases} \binom{n}{t} p^t (1-p)^{1-t} & t \in \{0, 1, \dots, n\} \\ 0 & \text{jinak} \end{cases}.$$

Na obrázku jsou pravděpodobnostní funkce pro  $Bi(50, 0.2)$ ,  $Bi(50, 0.5)$  a  $Bi(50, 0.9)$ . Rozdělení pravděpodobnosti dobře odpovídá intuici, že nejvíce výsledků bude blízko u hodnoty  $np$ :



S binomickým rozdělením se setkáváme velice často v praktických úlohách. Jednou z nich je popis náhodné veličiny, která popisuje počet  $X$  předmětů v jedné zvolené přihrádce z  $n$  možných, do nichž jsme náhodně rozdělili  $r$  předmětů.

Umístění kteréhokoliv předmětu do pevně zvolené přihrádky má pravděpodobnost  $1/n$  (každá z nich je stejně pravděpodobná).

Zjevně tedy bude pro jakýkoliv počet  $k = 0, \dots, r$

$$P(X = k) = \binom{r}{k} \left(\frac{1}{n}\right)^k \left(1 - \frac{1}{n}\right)^{r-k} = \binom{r}{k} \frac{(n-1)^{r-k}}{n^r},$$

jde proto o rozložení  $X$  typu  $\text{Bi}(r, 1/n)$ .

Jestliže nám bude vzrůstat počet přihrádek  $n$  společně s počtem předmětů  $r_n$  tak, že v průměru nám na každou přihrádku bude připadat (přibližně) stejný počet prvků  $\lambda$ , můžeme dobře vyjádřit chování našeho rozdělení veličin  $X_n$  při limitním přechodu  $n \rightarrow \infty$ :

Jestliže nám bude vzrůstat počet přihrádek  $n$  společně s počtem předmětů  $r_n$  tak, že v průměru nám na každou přihrádku bude připadat (přibližně) stejný počet prvků  $\lambda$ , můžeme dobře vyjádřit chování našeho rozdělení veličin  $X_n$  při limitním přechodu  $n \rightarrow \infty$ :

$$\begin{aligned} \lim_{n \rightarrow \infty} P(X_n = k) &= \lim_{n \rightarrow \infty} \binom{r_n}{k} \frac{(n-1)^{r_n-k}}{n^{r_n}} \\ &= \lim_{n \rightarrow \infty} \frac{r_n(r_n-1)\dots(r_n-k+1)}{(n-1)^k} \frac{1}{k!} \left(1 - \frac{1}{n}\right)^{r_n} \\ &= \frac{\lambda^k}{k!} \lim_{n \rightarrow \infty} \left(1 + \frac{-\frac{r_n}{n}}{r_n}\right)^{r_n} \\ &= \frac{\lambda^k}{k!} e^{-\lambda} \end{aligned}$$

protože obecně funkce  $(1 + x/n)^n$  konvergují stejnoměrně k funkci  $e^x$  na každém omezeném intervalu v  $\mathbb{R}$ .

To dává **Poissonovo rozdělení**  $Po(\lambda)$ .

# Poissonovo rozdělení

Poissonovo rozdělení  $Po(\lambda)$  popisuje např. události, které se vyskytují náhodně v čase a přitom pravděpodobnost výskytu v následujícím časovém intervalu o jednotkové délce nezávisí na předchozí historii a je rovna stále stejné hodnotě  $\lambda$ .

V praxi jsou takové procesy spojeny např. s poruchovostí strojů a zařízení.

# Poissonovo rozdělení

Poissonovo rozdělení  $Po(\lambda)$  popisuje např. události, které se vyskytují náhodně v čase a přitom pravděpodobnost výskytu v následujícím časovém intervalu o jednotkové délce nezávisí na předchozí historii a je rovna stále stejné hodnotě  $\lambda$ .

V praxi jsou takové procesy spojeny např. s poruchovostí strojů a zařízení.

## Theorem (Poissonova věta)

*Jsou-li  $X_n \sim \text{Bi}(n, p_n)$  a  $\lim_{n \rightarrow \infty} n \cdot p_n = \lambda$  je konečná, pak*

$$\lim_{n \rightarrow \infty} P(X_n = k) = P(X = k),$$

*kde  $X \sim \text{Po}(\lambda)$ .*

# Příklady spojitých rozdělání

Nejjednodušší je tzv. **rovnoměrné rozdělání**. Jestliže chceme, aby pravděpodobnost každé hodnoty v předem daném intervalu  $(a, b) \subset \mathbb{R}$  byla stejná, pak hustota  $f_X$  našeho rozdělání náhodné veličiny  $X$  má být konstantní. Pak ovšem jsou pro libovolná reálná čísla  $-\infty < a < b < \infty$  jen jediné možné hodnoty

$$f_X(t) = \begin{cases} 0 & t \leq a \\ \frac{1}{b-a} & t \in (a, b) \\ 0 & t \geq b, \end{cases} \quad F_X(t) = \begin{cases} 0 & t \leq a \\ \frac{t-a}{b-a} & t \in (a, b) \\ 1 & t \geq b. \end{cases}$$



# Exponenciální rozdělení $\text{ex}(\lambda)$

je dalším rozdělením, které je snadno určeno požadovanými vlastnostmi náhodné veličiny. Předpokládejme, že sledujeme výskyt náhodného jevu tak, že výskyty v nepřekrývajících se intervalech jsou nezávislé. Je-li tedy  $P(t)$  pravděpodobnost, že jev **nenastane** během intervalu délky  $t$ , pak nutně  $P(t+s) = P(t)P(s)$  pro všechna  $t, s > 0$ . Předpokládejme navíc diferencovatelnost funkce  $P$  a  $P(0) = 1$ . Pak  $\ln P(t+s) = \ln P(t) + \ln P(s)$ .

# Exponenciální rozdělení $\text{ex}(\lambda)$

je dalším rozdělením, které je snadno určeno požadovanými vlastnostmi náhodné veličiny. Předpokládejme, že sledujeme výskyt náhodného jevu tak, že výskyty v nepřekrývajících se intervalech jsou nezávislé. Je-li tedy  $P(t)$  pravděpodobnost, že jev **nenastane** během intervalu délky  $t$ , pak nutně  $P(t+s) = P(t)P(s)$  pro všechna  $t, s > 0$ . Předpokládejme navíc diferencovatelnost funkce  $P$  a  $P(0) = 1$ . Pak  $\ln P(t+s) = \ln P(t) + \ln P(s)$ . Limitním přechodem:

$$\lim_{s \rightarrow 0_+} \frac{\ln P(t+s) - \ln P(t)}{s} = (\ln P)'(0) = -\lambda.$$

Odtud vyplývá diferenciální rovnice

$$(\ln P(t))' = -\lambda.$$

Odtud dostáváme  $\ln P(t) = -\lambda t + C$  a počáteční podmínka dává jediné řešení

$$P(t) = e^{-\lambda t}.$$

Všimněme si, že z definice našich objektů vyplývá, že  $\lambda > 0$ .

Odtud dostáváme  $\ln P(t) = -\lambda t + C$  a počáteční podmínka dává jediné řešení

$$P(t) = e^{-\lambda t}.$$

Všimněme si, že z definice našich objektů vyplývá, že  $\lambda > 0$ . Uvažme náhodnou veličinu  $X$  udávající okamžik, kdy náš jev poprvé **nastane**. Zřejmě tedy je distribuční funkce rozdělení pro  $X$  dána

$$F_X(t) = 1 - P(t) = \begin{cases} 1 - e^{-\lambda t} & t > 0 \\ 0 & t \leq 0. \end{cases}$$

Je vidět, že je to rostoucí funkce s hodnotami mezi nulou a jedničkou a správnými limitami v  $\pm\infty$ .

Hustotu tohoto rozdělení dostaneme derivováním distribuční funkce, tj.

$$f_X = \begin{cases} \lambda e^{-\lambda t} & t > 0 \\ 0 & t \leq 0. \end{cases}$$




# Normální rozdělení

je ze všech nejdůležitější.

# Normální rozdělení

je ze všech nejdůležitější.

Jestliže v binomiálním rozdělení zachováme konstantní úspěšnost  $p$ , ale budeme přidávat počet pokusů  $n$ , bude pravděpodobnostní funkce kupodivu pořád mít podobný tvar (i když jiné rozměry). Na obrázku při rostoucím  $n$  se budou vynesené bodové hodnoty slévat do křivky, pro hodnoty  $Bi(500, 0.5)$  a  $Bi(5000, 0.5)$  je výsledek vidět na obrázku níže. Třetí křivka na obrázku je grafem funkce  $f(x) = e^{-x^2/2}$ .



Hledáme-li podobné spojité rozdělení, potřebovali bychom spočítat  $\int_a^b e^{-x^2/2} dx$  což není pomocí elementárních funkcí možné. Je však možné (i když ne úplně snadné) ověřit, že příslušný nevlastní integrál konverguje k hodnotě

$$\int_{-\infty}^{\infty} e^{-x^2/2} dx = \sqrt{2\pi}.$$

Odtud vyplývá, že možná hustota rozdělení náhodného rozdělení může být

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

Hledáme-li podobné spojitě rozdělení, potřebovali bychom spočítat  $\int_a^b e^{-x^2/2} dx$  což není pomocí elementárních funkcí možné. Je však možné (i když ne úplně snadné) ověřit, že příslušný nevlastní integrál konverguje k hodnotě

$$\int_{-\infty}^{\infty} e^{-x^2/2} dx = \sqrt{2\pi}.$$

Odtud vyplývá, že možná hustota rozdělení náhodného rozdělení může být

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

Rozdělení s touto hustotou se nazývá **normální rozdělení**  $N(0, 1)$ . Příslušnou distribuční funkci

$$F_X(x) = \int_{-\infty}^x e^{-x^2/2} dx$$

nelze vyjádřit pomocí elementárních funkcí, přesto se s ní numericky běžně počítá (pomocí tabulek nebo softwarových aplikací).



Hledáme-li podobné spojité rozdělení, potřebovali bychom spočítat  $\int_a^b e^{-x^2/2} dx$  což není pomocí elementárních funkcí možné. Je však možné (i když ne úplně snadné) ověřit, že příslušný nevlastní integrál konverguje k hodnotě

$$\int_{-\infty}^{\infty} e^{-x^2/2} dx = \sqrt{2\pi}.$$

Odtud vyplývá, že možná hustota rozdělení náhodného rozdělení může být

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

Rozdělení s touto hustotou se nazývá **normální rozdělení**  $N(0, 1)$ . Příslušnou distribuční funkci

$$F_X(x) = \int_{-\infty}^x e^{-x^2/2} dx$$

nelze vyjádřit pomocí elementárních funkcí, přesto se s ní numericky běžně počítá (pomocí tabulek nebo softwarových aplikací). Hustotě  $f_X$  se také často říká **Gaussova křivka**.

# Plán přednášky

- 1 Literatura
- 2 Pravděpodobnostní funkce a hustoty
- 3 Náhodné vektory**
- 4 Funkce náhodných veličin

Obdobně definujeme distribuční funkce a hustotu a pravděpodobnostní funkci pro spojité a diskrétní náhodné vektory. Hovoříme také o **simultánních (sdružených) pravděpodobnostních funkcích a hustotách**.

Pro dvě proměnné (vektor  $(X, Y)$  náhodných veličin):

$$f(x, y) = \begin{cases} P(X = x_i \wedge Y = y_j) & x = x_i \wedge y = y_j \\ 0 & \text{jinak.} \end{cases}$$

u diskrétních a pro všechny  $a, b \in \mathbb{R}$  pro spojité:

$$F(b, a) = P(-\infty < X < b, \infty < Y < a) = \int_{-\infty}^a \int_{-\infty}^b f(x, y) dx dy.$$

# Marginální rozložení

pro jednu z proměnných obdržíme tak, že přes ostatní počítáme nebo zintegrujeme. Např. u diskrétních vektorových veličin  $(X, Y)$  tvoří jevy  $(X = x_i, Y = y_j)$  pro všechny možné hodnoty  $x_i$  a  $y_j$  s nenulovými pravděpodobnostmi pro  $X$  a  $Y$  úplný systém jevů pro vektor  $(X, Y)$  a dostáváme vztah:

$$P(X = x_i) = \sum_{j=1}^{\infty} P(X = x_i, Y = y_j)$$

mezi **marginálním rozdělením pravděpodobnosti** náhodné veličiny  $X$  a **sduženým rozdělením pravděpodobnosti** náhodného vektoru  $(X, Y)$ .

Náhodné veličiny  $X$  a  $Y$  jsou **stochasticky nezávislé**, jestliže jejich sdružená distribuční funkce splňuje

$$F(x, y) = G(x) \cdot H(y),$$

kde  $G$  a  $H$  jsou distribuční funkce veličin  $X$  a  $Y$ .

# Plán přednášky

- 1 Literatura
- 2 Pravděpodobnostní funkce a hustoty
- 3 Náhodné vektory
- 4 Funkce náhodných veličin**

## Definition

Pro danou spojitou funkci  $\psi : \mathbb{R} \rightarrow \mathbb{R}$  a náhodnou veličinou  $X$  máme dánu také náhodnou veličinou  $Y = \psi(X)$ . Nazýváme ji **funkcí náhodné veličiny  $X$** .

V případě náhodného vektoru  $(X_1, \dots, X_n)$  a funkce  $\psi : \mathbb{R}^n \rightarrow \mathbb{R}$  hovoříme o funkci  $Y = \psi(X_1, \dots, X_n)$  náhodného vektoru.

Požadavek spojitosti  $\psi$  zaručuje, že je  $Y$  opět náhodnou veličinou podle naší definice, protože vzor borelovské množiny ve spojitém zobrazení je opět borelovská množina.

Obecněji můžeme právě tento požadavek na  $\psi$  vztáhnout pro každý speciální případ veličiny či vektoru a definovat tak pojem funkce z náhodné veličiny či vektoru obecněji.

Nejjednodušší funkcí po konstantách je afinní závislost

$$\psi(X) = a + bX$$

s konstantami  $a, b \in \mathbb{R}$ ,  $b \neq 0$ .

Je-li  $f_X(x)$  pravděpodobnostní funkce náhodné veličiny s diskrétním rozdělením, snadno se vypočte

$$f_{\psi(X)}(y) = P(\psi(X) = y) = \sum_{\psi(x_i)=y} f(x_i).$$

V případě afinní závislosti  $Y = a + bX$  je proto pravděpodobnostní funkce nenulová právě v bodech  $y_i = ax_i + b$ .

Např. součet  $n$  nezávislých náhodných veličin s alternativním rozdělením  $A(p)$  je veličina s binomiální rozdělení  $\text{Bi}(n, p)$ .



Podobně můžeme přepočíst distribuční funkci rozdělení funkce ze spojitě náhodné veličiny, či vektoru.

Např. má-li  $Z$  s normální rozdělení  $N(0, 1)$ , pak veličiny  $Y = \mu + \sigma Z$  budou mít normální rozdělení  $N(\mu, \sigma)$ .

Podobně můžeme přepočíst distribuční funkci rozdělení funkce ze spojitě náhodné veličiny, či vektoru.

Např. má-li  $Z$  s normální rozdělení  $N(0, 1)$ , pak veličiny  $Y = \mu + \sigma Z$  budou mít normální rozdělení  $N(\mu, \sigma)$ .

Se součty nezávislých spojitých veličin  $X$  a  $Y$  s hustotami  $f_X$  a  $f_Y$  je to složitější. Přímým výpočtem spočteme distribuční funkci náhodné promnné  $V = X + Y$ .

$$\begin{aligned} F_V(u) &= \int_{x+y < u} f_X(x) f_Y(y) dx dy \\ &= \int_{-\infty}^u \left( \int_{-\infty}^{\infty} f_X(x) f_Y(v-x) dx \right) dv. \end{aligned}$$

Je tedy sdruženou hustotou součtu dvou nezávislých veličin právě konvoluce jejich hustot

$$f_V = f_X * f_Y.$$