

Poznámky k předmětu Aplikovaná statistika, 5.téma

5. Některá významná rozdělení

A. Diskrétní rozdělení

- (i) Diskrétní rovnoměrné rozdělení na množině $\{1, \dots, n\}$

Náhodná veličina X , která má diskrétní rovnoměrné rozdělení (značíme $X \sim R(\{1, \dots, n\})$) nabývá pouze hodnot z množiny $\{1, \dots, n\}$ a to s pravděpodobností $\frac{1}{n}$, tj.

$$\mathbb{P}(X = i) = \frac{1}{n}, \quad i \in \{1, \dots, n\}.$$

Střední hodnota: $\mathbb{E}X = \frac{n+1}{2}$.

Rozptyl: $\text{var}X = \frac{n^2-1}{12}$.

- (ii) Alternativní rozdělení $X \sim Alt(p)$, $p \in (0, 1)$

Náhodná veličina X mající alternativní rozdělení nabývá pouze hodnot 0 a 1 a to s následujícími pravděpodobnostmi:

$$\begin{aligned}\mathbb{P}(X = 1) &= p, \\ \mathbb{P}(X = 0) &= 1 - p.\end{aligned}$$

Střední hodnota: $\mathbb{E}X = p$.

Rozptyl: $\text{var}X = p(1 - p)$.

Příklad 1. Házíme na basketbalový koš ze šestky. V 80% případů se trefíme. Náhodná veličina X , která nabývá hodnoty 1, trefíme-li koš a hodnoty 0, jestliže koš netrefíme, má rozdělení $Alt(0, 8)$.

- (iii) Binomické rozdělení $X \sim Bi(n, p)$, $n \in \mathbb{N}$, $p \in (0, 1)$

Náhodná veličina X nabývá hodnot $k = 0, \dots, n$ s pravděpodobnostmi

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}, \quad k = 0, 1, \dots, n.$$

Náhodnou veličinou $X \sim Bi(n, p)$ se modeluje počet úspěchů v n **nezávislých** pokusech, je-li pravděpodobnost úspěchu v jednotlivých pokusech rovna p . Zevrubně řečeno, označme náhodné veličiny

$Y_i \dots$ výsledek i -tého pokusu, $i = 1, \dots, n$.

Pak

$$\begin{aligned}\mathbb{P}(Y_i = 1) &= p, \\ \mathbb{P}(Y_i = 0) &= 1 - p.\end{aligned}$$

a veličiny Y_i jsou nezávislé a mají alternativní rozdělení s parametrem p . Veličina X se potom dá zapsat jako

$$X = \sum_{i=1}^n Y_i.$$

Tedy veličina $X \sim Bi(n, p)$ se dá interpretovat jako součet n nezávislých veličin s rozdělením $Alt(p)$.

Bez této interpretace by pro nás počítání **střední hodnoty** a rozptylu bylo pro obecné n, p dosti obtížné (vyžaduje znalostí sčítání řad), ovšem takto je výpočet velmi přímočarý:

$$\mathbb{E}X = \mathbb{E} \sum_{i=1}^n Y_i = \sum_{i=1}^n \mathbb{E}Y_i = \sum_{i=1}^n p = np.$$

Rozptyl se délky nezávislosti veličin Y_i vypočítá analogicky,

$$\text{var}X = np(1 - p).$$

Příklad 2. Házíme desetkrát na koš. Pravděpodobnost, že se v jednotlivých hodech trefíme je opět 0, 8. Potom náhodná veličina Y popisující počet trefených košů při těchto deseti hodech má binomické rozdělení $Bi(10; 0, 8)$.

(iv) Geometrické rozdělení $X \sim Ge(p)$, $p \in (0, 1)$

Náhodná veličina X nabývá hodnot $k = 0, 1, \dots$ s pravděpodobnostmi

$$\mathbb{P}(X = k) = p(1 - p)^k, \quad k = 0, 1, \dots$$

Geometrickým rozdělením se modeluje počet neúspěšných pokusů před prvním úspěchem, jsou-li jednotlivé pokusy nezávislé a pravděpodobnost úspěchu je p .

Střední hodnota: $\mathbb{E}X = \frac{1-p}{p}$.

Rozptyl: $\text{var}X = \frac{1-p}{p^2}$.

Příklad 3. Házíme opět na koš. Počítáme si, jak dlouho, respektive kolik hodů, nám trvá, než se poprvé trefíme. Náhodná veličina Z udávající počet neúspěšných hodů před prvním úspěšným má geometrické rozdělení $Ge(0, 8)$.

(v) Poissonovo rozdělení $X \sim Po(\lambda)$, $\lambda > 0$

Rozdělení veličiny X je dáno pravděpodobnostní funkcí

$$\mathbb{P}(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \text{pro } k = 0, 1, \dots$$

Poissonovým rozdělením modelujeme náhodnou veličinu, která vyjadřuje počet výskytů události v určitém intervalu (času, délky, objemu, ...), jestliže události nastávají náhodně a nezávisle na sobě.

Střední hodnota: $\mathbb{E}X = \lambda$.

Rozptyl: $\text{var}X = \lambda$.

Spojitost s binomickým rozdělením:

Uvažujme náhodnou veličinu $X \sim Bi(n, p)$, kde $n \rightarrow \infty$, $p \rightarrow 0$, a $np = \lambda$. Potom

$$P(X = k) = \frac{n(n-1)\dots(n-k+1)}{k!} p^k \left(1 - \frac{\lambda}{n}\right)^{n-k} \xrightarrow[n \rightarrow \infty, p \rightarrow 0]{} \frac{\lambda^k}{k!} e^{-\lambda},$$

tedy veličina X má asymptoticky Poissonovo rozdělení.

Cvičení k tomuto tématu

- (i) Ve velké várce vajec je $1/3$ zkažených. Jaká je pravděpodobnost, že ze šesti náhodně vybraných vajec budou nejvýše dvě zkažená? Nadto nakreslete graf pravděpodobnostní funkce příslušné náhodné veličiny.
- (ii) Na telefonní ústřednu přichází průměrně 100 hovorů za jednu hodinu, přičemž příchody hovorů jsou náhodné. Jaká je pravděpodobnost, že
 - (a) když telefonistka odejde na deset minut do kuchyňky, nezmešká žádný hovor?
 - (b) ve třech minutách přijdou více než dva hovory?
- (iiia) Ve výrobní hale je 8 stejných žárovek. Pravděpodobnost, že během směny praskne jedna žárovka, je $0,4$. Žárovky praskají nezávisle a nelze je během směny vyměnit. Když jich praskne více než 5, musí pracovníci za tuto směnu dostat příplatek. Jaká je pravděpodobnost, že za příští směnu dostanou příplatek?
- (iiib) Ve výrobní hale je velké množství žárovek. Ví se, že za směnu praskne průměrně 3,2 žárovky. Jaká je pravděpodobnost, že během příští směny praskne více než 5 žárovek (a pracovníci dostanou příplatek)? Nakreslete graf pravděpodobnostní funkce příslušné náhodné veličiny.

B. Spojitá rozdělení

- (i) Rovnoměrné rozdělení na intervalu $[a, b]$ $X \sim R([a, b]), a < b \in \mathbb{R}$

Má hustotu pravděpodobnosti

$$f(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b, \\ 0 & x < a, \quad x > b. \end{cases}$$

Tato hustota je konstantní na $[a, b]$, což skutečně odpovídá tomu, že pravděpodobnost, že X padne do podintervalu intervalu $[a, b]$, je úměrná velikosti tohoto podintervalu vůči $[a, b]$. (Srovnejte s geometrickou pravděpodobností.)

Distribuční funkce je pak

$$F(x) = \begin{cases} 0 & x < a, \\ \frac{x-a}{b-a} & a \leq x \leq b, \\ 1 & x \geq b. \end{cases}$$

Prostým integrováním obdržíme vzorce pro střední hodnotu a rozptyl. Povšimněme si, že střední hodnota je přesně uprostřed intervalu $[a, b]$.

Střední hodnota: $\mathbb{E}X = \frac{a+b}{2}$.

Rozptyl: $\text{var}X = \frac{1}{12}(b-a)^2$.

- (ii) Exponenciální rozdělení $X \sim \text{Exp}(\lambda), \lambda > 0$

Veličina X nabývá hodnot z intervalu $(0, \infty)$.

Hustota závisí na parametru λ a je dána vztahem

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

Distribuční funkce F :

$$F(x) = \begin{cases} 0 & \text{pro } x \leq 0, \\ 1 - e^{-\lambda x} & x > 0. \end{cases}$$

Střední hodnota: $\mathbb{E}X = \frac{1}{\lambda}$.

Rozptyl: $\text{var}X = \frac{1}{\lambda^2}$.

Exponenciální rozdělení je rozdělení „bez paměti“:

Pro náhodnou veličinu X s exponenciálním rozdělením platí:

$$P(X > x + y | X > y) = P(X > x), \quad \forall x > 0, y > 0,$$

neboť užitím definice podmíněné pravděpodobnosti můžeme pravděpodobnost $P(X > x + y | X > y)$ přepsat ve tvaru

$$\frac{P(X > x + y)}{P(X > y)} = \frac{e^{-\lambda(x+y)}}{e^{-\lambda y}} = e^{-\lambda x}.$$

Exponenciálním rozdělením se modeluje doba čekání na událost a má velký význam v teorii přežití a v kombinaci s Poissonovým rozdělením i v systémech hromadné obsluhy (viz níže).

Souvislost s Poissonovým rozdělením:

Jestliže náhodá veličina X , která popisuje dobu čekání na výskyt události, má rozdělení $Exp(\lambda)$, potom n.v. Y popisující počet těchto událostí, jež nastaly v časovém intervalu délky T , má Poissonovo rozdělení $Po(\lambda T)$.

- (iii) Normální rozdělení $X \sim \mathcal{N}(\mu, \sigma^2)$, $\mu \in \mathbb{R}$, $\sigma^2 > 0$

Říká se mu také **Gaussovo rozdělení**. Veličina X nabývá hodnot z celého \mathbb{R} .

Hustota normálního rozdělení je

$$f(x) = \frac{1}{\sqrt{2\pi \sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < \infty,$$

a říká se jí **Gaussovka křivka**.

Distribuční funkce je

$$F(x) = \frac{1}{\sqrt{2\pi \sigma^2}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt, \quad -\infty < x < \infty,$$

a **nelze** ji explicitně vyjádřit vzorcem.


Normální rozdělení má v teorii pravděpodobnosti a matematické statistice zásadní roli, jak se dozvím v další kapitole. Velmi hrubě řečeno se dá normálním rozdělením modelovat součet velmi mnoha drobných náhodných faktorů.

Střední hodnota: $\mathbb{E}X = \mu$.

Rozptyl: $\text{var}X = \sigma^2$.

- (iiib) Normované normální rozdělení $X \sim \mathcal{N}(0, 1)$

Je znormovaná náhodná veličina s normálním rozdělením, tj. $\mu = \mathbb{E}X = 0$ a $\sigma^2 = \text{var}X = 1$.



Obrázek 1: Hustota $\mathcal{N}(0, 49)$.

Hustota normovaného normálního rozdělení je

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}, \quad -\infty < x < \infty.$$

Distribuční funkce Φ je

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

a její hodnoty jsou tabelizovány (lze je nalézti ve statistických tabulkách).

Díky symetrii hustoty ϕ platí:

$$\Phi(x) = 1 - \Phi(-x), \quad x \in \mathbb{R},$$

a tudíž je dostatečné tabelizovat hodnoty $\Phi(x)$ pro nezáporné hodnoty x .

Transformace normálně rozdělených veličin

1. Jestliže Y má normální rozdělení s parametry μ a σ^2 , potom

$$X = \frac{Y - \mu}{\sigma}$$


má normované normální rozdělení $\mathcal{N}(0, 1)$.

2. Jestliže X má normální rozdělení s parametry μ a σ^2 a $Y = a + bX$, potom Y má opět normální rozdělení s parametry $a + b\mu$ a $b^2\sigma^2$.
3. Uvažujme náhodné veličiny X a Y , $X \sim \mathcal{N}(\mu_1, \sigma_1^2)$, $Y \sim \mathcal{N}(\mu_2, \sigma_2^2)$, jsou **nezávislé**. Potom n.v. $Z = aX + bY + c$ má rozdělení $\mathcal{N}(a\mu_1 + b\mu_2 + c, a^2\sigma_1^2 + b^2\sigma_2^2)$.

Díky vztahu 1. není třeba tabelizovat hodnoty distribuční funkce F pro všechna rozdělení $\mathcal{N}(\mu, \sigma^2)$ (to by ani nebylo možné!), ale stačí nám tabulka pro Φ , neboť pro všechny distribuční funkce F platí vztah

$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right).$$

U následujících rozdělení si uvedeme pouze jejich definice bez dalších vlastností. Tato rozdělení budou hrát důležitou roli při pozdějším testování hypotéz.



Obrázek 2: Distribuční funkce $\mathcal{N}(0, 1)$.

- (iv) χ^2 - rozdelení o n stupních volnosti $X \sim \chi^2(n)$

Nechť X_1, \dots, X_n jsou nezávislé náhodné veličiny s normovaným normálním rozdelením $\mathcal{N}(0, 1)$. Potom náhodná veličina

$$Y_n = \sum_{i=1}^n X_i^2$$

má tzv. χ^2 - rozdelení o n stupních volnosti. Symbolem $\chi_\alpha^2(n)$ budeme značit α -kvantily tohoto rozdělení.

- (v) Studentovo rozdelení o n stupních volnosti $X \sim t(n)$

Nechť U a V jsou nezávislé náhodné veličiny, $U \sim \mathcal{N}(0, 1)$ a $V \sim \chi^2(n)$. Potom náhodná veličina

$$W = \frac{U}{\sqrt{\frac{V}{n}}}$$

má tzv. Studentovo rozdelení (nebo též **t-rozdělení**) o n stupních volnosti. Symbolem $t_\alpha(n)$ budeme značit α -kvantily tohoto rozdělení.

- (vi) Fisherovo–Snedecorovo rozdelení $X \sim F(m, n)$

Uvažujme nezávislé náhodné veličiny $U_{n_1} \sim \chi^2(n_1)$ a $U_{n_2} \sim \chi^2(n_2)$. Potom náhodná veličina

$$Z = \frac{\frac{U_{n_1}}{n_1}}{\frac{U_{n_2}}{n_2}}$$

má tzv. Fisherovo–Snedecorovo rozdelení o n_1, n_2 stupních volnosti. Symbolem $F_\alpha(n_1, n_2)$ budeme značit α -kvantily tohoto rozdělení. Platí:

$$F_\alpha(n_1, n_2) = \frac{1}{F_{1-\alpha}(n_2, n_1)}.$$

Cvičení k tomuto tématu

- (iv) Babička chodí k vnoučkovi na návštěvu náhodně mezi první a šestou hodinou odpolední. Dnes však odchází vnouček ve čtyři hodiny na fotbal. Jaká je pravděpodobnost, že babička vnoučka doma nezastihne? Dále spočtěte střední hodnotu, rozptyl a distribuční funkci příslušné náhodné veličiny.
- (v) Nechť $X \sim \mathcal{N}(2, 16)$. Pomocí tabulky distribuční funkce $\Phi(x)$ určete
- (a) $\mathbb{P}(-4 \leq X < 5)$,
 - (b) $\mathbb{P}(X > 8, 5)$,
 - (c) $\mathbb{P}(X = 3)$,
 - (d) $\mathbb{P}(X < 18)$.
- (vi) Náhodná veličina X udává odchylku obsahu cukru v jednotlivých bonbónech od normy (udaná v gramech). Ví se, že $X \sim \mathcal{N}(0, 1)$. Výrobce potřebuje znát takovou hodnotu h (v gramech), že bonbónů, v nichž obsah cukru převýší normu o více než h , bude právě
- (a) 1%,
 - (b) 12%.
- Dále výrobce potřebuje znát takové h , že bonbónů, v nichž se obsah cukru bude lišit od normy o více než h , bude právě 1%.
- (vii) Nechť $X \sim \mathcal{N}(3, 10)$ a $Y \sim \mathcal{N}(1, 9)$ jsou nezávislé. Definujme náhodné veličiny

$$U := 3X - 1, \quad V := 2X - 3Y + 2.$$

Hledejme

- (a) $\mathbb{P}(U < 15)$,
 - (b) $\mathbb{P}(V > 2)$,
 - (c) $\mathbb{P}(|V| \leq 6)$,
 - (d) $\rho(X, Y)$ a $\rho(U, X)$,
 - (e) $\rho(V, X)$ a $\rho(U, V)$.
- (viii) Na toalety ve čtvrtém patře budovy C přichází „uživatel“ v průměru jednou za tři minuty. Na těchto toaletách se nachází také sprchy a právě ted' tu nikdo není. Jaká je pravděpodobnost, že během následujících deseti minut nikdo nepřijde a Vy se tak stihnete v klidu vysprchovat? Jaká je pravděpodobnost, že budete vyrušeni už za pět minut?
- (dcv) Na trávníku o rozloze $50 \times 100 \text{ m}^2$ se během sezóny udělá přibližně 120 krtinců na zcela náhodných místech. Majitel na něm chce udělat green o ploše 100 m^2 . Jaká je pravděpodobnost, že na greenu
- (a) nebude za sezónu žádný krtinec?
 - (b) budou za sezónu více než tři krtince?

Nakrestele pravděpodobnostní funkci příslušné náhodné veličiny.