

Třída rozdělení $(a, b, 0)$

Definice

Nechť $p_N(k) = P(N = k)$ je pravděpodobnostní funkce diskrétní náhodné veličiny N . Řekneme, že je členem třídy rozdělení $(a, b, 0)$, jestliže existují reálné konstanty a a b takové, že platí

$$\frac{p_N(k)}{p_N(k-1)} = a + \frac{b}{k} \quad \text{pro } k = 1, 2, 3, \dots \quad (1)$$

- pravděpodobnost $p_N(0)$ dopočítáme z $\sum_{k=0}^{\infty} p_N(k) = 1$

- do třídy rozdělení $(a, b, 0)$ patří právě Poissonovo rozdělení, negativně binomické a binomické rozdělení
- Pro Poissonovo rozdělení je $a = 0$ a $b = \lambda$.
- Pro binomické je $a = -\frac{p}{1-p} < 0$ a $b = (n + 1)\frac{p}{1-p}$.
- Pro NeBi je $a = 1 - p > 0$ a $b = (m - 1)(1 - p)$.

- pro konkrétní datový soubor s velkým množstvím pozorování lze určit vhodný model pomocí formule (1)
- formuli přepíšeme do tvaru

$$\frac{p_N(k)}{p_N(k-1)} \cdot k = ak + b, \quad k = 1, 2, 3, \dots \quad (2)$$

- podíl $\frac{p_N(k)}{p_N(k-1)}$ odhadneme na základě pozorovaných četností n_k a n_{k-1} hodnot k a $k-1$

$$\frac{\widehat{p_N(k)}}{\widehat{p_N(k-1)}} \cdot k = \frac{n_k}{n_{k-1}} \cdot k. \quad (3)$$

- graf procházející body $\left[k, k \cdot \frac{n_k}{n_{k-1}} \right]$ by měl přibližně vykazovat **lineární průběh**
- podle směrnice a dané přímky zvolíme vhodný model
 - nulová směrnice \rightarrow Poissonovo rozdělení
 - záporná směrnice \rightarrow binomické rozdělení
 - kladná směrnice \rightarrow negativně binomické rozdělení

Třída rozdělení $(a, b, 1)$

- rozdělení třídy $(a, b, 0)$ často nepopisují adekvátně data, s nimiž se v praxi setkáváme

Hlavní příčina:

- rozdělení třídy $(a, b, 0)$ nejsou s to vystihnout tvar dat v jistých částech rozdělení, zejména **hodnotu v nule**.
- budeme se věnovat rozložení pravděpodobnosti v nule (pravděpodobnost, že nenastane **žádná pojistná událost** během stanoveného časového období) – např. u pojištění odpovědnosti, majetku aj. je pravděpodobnost v nule *největší*
- úpravou pravděpodobnosti v nule lze třídu rozdělení $(a, b, 0)$ rozšířit na třídu $(a, b, 1)$

Definice

Nechť $p_N(k)$ je pravděpodobnostní funkce diskrétní náhodné veličiny N . Řekneme, že je členem třídy rozdělení $(a, b, 1)$ za předpokladu, že existují konstanty $a, b \in \mathbb{R}$ takové, že

$$\frac{p_N(k)}{p_N(k-1)} = a + \frac{b}{k} \quad \text{pro } k = 2, 3, \dots \quad (4)$$

- $\sum_{k=1}^{\infty} p_N(k)$ může nabývat libovolných hodnot na $(0, 1)$, zbývající pravděpodobnost je v $k = 0$, jelikož $p_N(0) + \sum_{k=1}^{\infty} p_N(k) = 1$

U třídy $(a, b, 1)$ rozlišujeme dvě podtřídy

$p_N(0) = 0$... rozdělení useknuté v nule s $p_N^T(k)$

$p_N(0) > 0$... rozdělení modifikované v nule s $p_N^M(k)$

1. Rozdělení modifikovaná v nule

lze na ně pohlížet jako na směs rozdělení třídy $(a, b, 0)$ a degenerovaného rozdělení se všemi pravděpodobnostmi soustředěnými v nule

- $G_N(s) = \sum_{k=0}^{\infty} p_N(k) \cdot s^k$ je generující funkce rozdělení třídy $(a, b, 0)$

$G_N^M(s) = \sum_{k=0}^{\infty} p_N^M(k) \cdot s^k$ je generující funkce příslušného v nule modifikovaného rozdělení třídy $(a, b, 1)$

- platí, že $p_N^M(k) = c \cdot p_N(k)$ pro $k = 1, 2, \dots$; $c \in \mathbb{R}^+$ a $p_N^M(0)$ je libovolně zvolené z intervalu $(0, 1)$. Musíme *vypočítat hodnotu* c .

- potom

$$\begin{aligned} G_N^M(s) &= p_N^M(0) + \sum_{k=1}^{\infty} p_N^M(k) \cdot s^k = \\ &= p_N^M(0) + c \cdot \sum_{k=1}^{\infty} p_N(k) \cdot s^k = \\ &= p_N^M(0) + c \cdot (G_N(s) - p_N(0)) \end{aligned} \quad (5)$$

- z platnosti $G_N^M(1) = G_N(1) = 1$ plyne $1 = p_N^M(0) + c \cdot (1 - p_N(0))$
- odtud $c = \frac{1 - p_N^M(0)}{1 - p_N(0)}$
- tudíž

$$p_N^M(k) = \frac{1 - p_N^M(0)}{1 - p_N(0)} \cdot p_N(k) \quad \text{pro } k = 1, 2, \dots \quad (6)$$

- dostaneme generující funkci modifikovaného rozdělení

$$\begin{aligned}
 G_N^M(s) &= p_N^M(0) + c \cdot (G_N(s) - p_N(0)) = \\
 &= p_N^M(0) + \frac{1 - p_N^M(0)}{1 - p_N(0)} \cdot (G_N(s) - p_N(0)) = \\
 &= \frac{p_N^M(0) - p_N(0)}{1 - p_N(0)} + \frac{1 - p_N^M(0)}{1 - p_N(0)} \cdot G_N(s) = \\
 &= \frac{p_N^M(0) - 1 + 1 - p_N(0)}{1 - p_N(0)} + \frac{1 - p_N^M(0)}{1 - p_N(0)} \cdot G_N(s) = \\
 &= \left(1 - \frac{1 - p_N^M(0)}{1 - p_N(0)} \right) + \frac{1 - p_N^M(0)}{1 - p_N(0)} \cdot G_N(s)
 \end{aligned} \tag{7}$$

2. Rozdělení useknutá v nule

lze chápat jako speciální typ v nule modifikovaného rozdělení s hodnotou $p_N^M(0) = 0$

- $G_N^T(s)$ je generující funkce v nule useknutého rozdělení
- potom z (6), (7) a $p_N^M(0) = 0$ získáme

$$p_N^T(k) = \frac{p_N(k)}{1 - p_N(0)} \quad \text{pro } k = 1, 2, \dots, \quad (8)$$

$$G_N^T(s) = \frac{G_N(s) - p_N(0)}{1 - p_N(0)} \quad (9)$$

a) rozšířené useknuté negativně binomické (ETNB) rozdělení

množina možných hodnot parametru m je rozšířena z $m > 0$ na $m > -1$, přičemž $m \neq 0$

Pravděpodobnostní funkce:

$$p_N^T(k) = \begin{cases} \frac{\binom{k+m-1}{k} \cdot (1-p)^k}{p^{-m}-1}, & k = 1, 2, \dots; p \in (0, 1), \\ 0, & \text{jinak,} \end{cases} \quad (10)$$

resp.

$$p_N^T(k) = \begin{cases} \frac{\binom{k+m-1}{k} \cdot \left(\frac{\beta}{1+\beta}\right)^k}{(1+\beta)^{m-1}} = & k = 1, 2, \dots; \\ = \frac{(k+m-1) \cdot \dots \cdot (m+1) \cdot m}{k! \cdot ((1+\beta)^{m-1})} \cdot \left(\frac{\beta}{1+\beta}\right)^k, & \beta = \frac{1-p}{p} > 0, \\ 0, & \text{jinak.} \end{cases} \quad (11)$$

b) logaritmické rozdělení

- je limitním případem ETNB rozdělení pro $m \rightarrow 0$
- neexistuje k němu odpovídající rozdělení ve třídě $(a, b, 0)$

Pravděpodobnostní funkce:

$$p_N^T(k) = \begin{cases} -\frac{(1-p)^k}{k \cdot \ln(p)}, & k = 1, 2, \dots; p \in (0, 1), \\ 0, & \text{jinak,} \end{cases} \quad (12)$$

resp.

$$p_N^T(k) = \begin{cases} \frac{\beta^k}{k(1+\beta)^k \ln(1+\beta)}, & k = 1, 2, \dots; \beta = \frac{1-p}{p} > 0, \\ 0, & \text{jinak.} \end{cases} \quad (13)$$

Opět lze dokázat že další taková rozdělení *neexistují*.

Další třídy čítecích rozdělí vytvoříme pomocí dvou *operací*

– *Skládání*

– *Míšení* (směsi)

K tomu budeme potřebovat některé nástroje z teorie pravděpodobnosti.

Diskrétní náhodné proměnné

Nechť X je diskrétní náhodná proměnná (náhodná veličina), tedy funkce

$$X : \Omega \rightarrow \{x_1, x_2, \dots\} \subseteq \mathbb{R},$$

kde $\{x_1, x_2, \dots\}$ je diskrétní podmnožina \mathbb{R} .

Pravděpodobnostní funkci náhodné veličiny X označíme jako

$$f(x) = P(X = x).$$

Definice 2.1. *Distribuční funkce* náhodné veličiny X je

$$F(x) = P(X \leq x).$$

Připomeňme si ještě definici nezávislosti dvou jevů.

Definice 2.2. Jevy $A, B \subseteq \Omega$ jsou **nezávislé**, jestliže

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

tedy

$$P(A \cap B) = P(A)P(B).$$

Jinak řečeno nastal-li jev B , *nezmění* to pravděpodobnost jevu A .

Definice 2.3. Diskrétní náhodné veličiny X a Y jsou *nezávislé*, jestliže jevy $\{X = x\}$ a $\{Y = y\}$ jsou nezávislé pro všechna x a y .

Jinými slovy, znalost hodnoty X nedává žádnou informaci o hodnotě Y .

Závislost a nezávislost náhodných veličin

Lemma 2.4. *Necht' X a Y jsou nezávislé náhodné veličiny.
Potom*

$$E(XY) = E(X)E(Y).$$

Opak obecně neplatí.

Definice 2.5. Říkáme, že náhodné veličiny X a Y jsou *nekorelované*, jestliže platí:

$$E(XY) = E(X)E(Y).$$

Věta 2.6. *Nechť X a Y jsou náhodné veličiny. Pak*

— $\text{Var}(aX) = a^2 \text{Var}(X)$ pro $a \in \mathbb{R}$.

— *Jsou-li X a Y nekorelované (speciálně nezávislé) náhodné veličiny, pak*

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y).$$

Definice 2.7. *Kovariance* náhodných veličin X a Y je definována jako

$$\text{cov}(X, Y) = E [(X - E(X))(Y - E(Y))].$$

Korelační koeficient X a Y je

$$\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$

Platí:

$$\rho(X, Y) = 0 \Leftrightarrow E(XY) = E(X)E(Y) \Leftrightarrow \text{cov}(X, Y) = 0$$

a

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

Dále je

$$|\rho(X, Y)| \leq 1.$$

Jak ověřit nezávislost dvou daných náhodných veličin?

Definice k tomu většinou vhodná není.

Definice 2.8. Necht' X a Y jsou diskrétní náhodné veličiny (na stejném pravděpodobnostním prostoru). *Sdružená distribuční funkce* X a Y je definovaná vztahem

$$F_{X,Y}(x, y) = P(X \leq x \wedge Y \leq y).$$

Definice 2.9. *Sdružená pravděpodobnostní funkce:*

$f_{X,Y} : \mathbb{R}^2 \rightarrow [0, 1]$ je definovaná vztahem

$$f_{X,Y}(x, y) = P(X = x \wedge Y = y).$$

Analogicky se definuje sdružená pravděpodobnostní funkce pro více náhodných veličin. Následující lemma dává dobře ověřitelné kritérium nezávislosti.

Lemma 2.10. *Diskrétní náhodné veličiny X a Y jsou nezávislé právě tehdy, když*

$$f_{X,Y}(x, y) = f_X(x)f_Y(y)$$

pro všechna $x, y \in \mathbb{R}$.

Ze znalosti sdružené pravděpodobnostní funkce $f_{X,Y}$ můžeme vypočítat *marginální pravděpodobnostní funkce* f_X a f_Y . Máme

$$\begin{aligned} f_X(x) &= P(X = x) = P\left(\bigcup_y (\{X = x\} \cap \{Y = y\})\right) \\ &= \sum_y P(X = x \wedge Y = y) = \sum_y f_{X,Y}(x, y). \end{aligned}$$

Příklad 2.11. Necht' $X : \Omega \rightarrow \{1, 2, 3\}$ a $Y : \Omega \rightarrow \{-1, 0, 2\}$ jsou náhodné veličiny a sdružená pravděpodobnostní funkce je dána tabulkou:

	$y = -1$	$y = 0$	$y = 2$	f_X
$x = 1$	$\frac{1}{18}$	$\frac{3}{18}$	$\frac{2}{18}$	$\frac{6}{18}$
$x = 2$	$\frac{2}{18}$	0	$\frac{3}{18}$	$\frac{5}{18}$
$x = 3$	0	$\frac{4}{18}$	$\frac{3}{18}$	$\frac{7}{18}$
f_Y	$\frac{3}{18}$	$\frac{7}{18}$	$\frac{8}{18}$	$\frac{18}{18}$

Jsou X a Y nezávislé?

Zřejmě ne, v tom případě by řádky tabulky musely být násobkem jeden druhého.

Vypočteme kovarianci těchto dvou náhodných veličin. Máme

$$XY : \Omega \rightarrow \{-1, 0, -2, -3, 2, 4, 6\}.$$

Dále

$$E(X) = \frac{6}{18} + \frac{10}{18} + \frac{21}{18} = \frac{37}{18}, \quad E(Y) = \frac{13}{18}$$

a

$$E(XY) = -1\frac{1}{18} + 2\frac{2}{18} - 2\frac{2}{18} + 4\frac{3}{18} + 6\frac{3}{18} = \frac{29}{18}$$

Celkem tedy

$$\text{cov}(X, Y) = E(XY) - E(X)E(Y) = \frac{29}{18} - \frac{481}{324} = \frac{522 - 481}{324} = \frac{41}{324}.$$

Podmíněná pravděpodobnost a podmíněné očekávání

Připomněme definici podmíněné pravděpodobnosti pro jevy,

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

V modelech pojistné a finanční matematiky je obvykle pravděpodobnost podmíněná informací, kterou máme v danou chvíli. Formálně to zachycuje následující definice.

Definice 2.12. Podmíněná pravděpodobnostní funkce náhodné veličiny Y za podmínky $X = x$, kterou budeme označovat $f_{Y|X}(\cdot | x)$, je definována jako

$$f_{Y|X}(y | x) = P(Y = y | X = x),$$

pro každé x takové, že $P(X = x) > 0$.

Z definice máme

$$P(Y = y | X = x) = \frac{P(Y = y \wedge X = x)}{P(X = x)} = \frac{f_{X,Y}(x, y)}{f_X(x)},$$

tedy

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

což je analogický vztah jako platí pro podmíněné pravděpodobnosti **jevů**.

V předchozím příkladu máme pro $x = 1$

$$f_{Y|X}(y | 1) \sim \left(\frac{1}{6}, \frac{3}{6}, \frac{2}{6} \right) = \frac{f_{X,Y}}{f_X}.$$

Víme-li, že $X = x$, pak Y má novou pravděpodobnostní funkci $f_{Y|X}(y | x)$ jakožto funkci y (x je pevné).

Očekávání vůči této funkci je **podmíněné očekávání** Y za podmínky $X = x$, které označíme $\Psi(x) = E(Y | X = x)$.

Definice 2.13. Funkce (tj. **náhodná veličina**)

$$\Psi(x) = E(Y \mid X = x)$$

se nazývá **podmíněné očekávání** Y při znalosti X .

V minulém příkladu je:

$$\Psi(1) = \frac{1}{6}(-1) + \frac{3}{6}0 + \frac{2}{6}2 = \frac{1}{2},$$

$$\Psi(2) = \frac{-2}{5} + \frac{6}{5} = \frac{4}{5}$$

a $\Psi(3) = \frac{6}{7}$.

Věta 2.14. (*O celkovém očekávání*). Pro podmíněné očekávání $\Psi(x) = E(Y | X = x)$ platí

$$E(\Psi(x)) = E(Y),$$

tedy

$$E(Y) = E(E(Y|X)).$$

- Opravdu, střední hodnotu náhodné veličiny $E(Y|X)$ lze vypočítat

$$\begin{aligned} E[E(Y|X)] &= \sum_x E(Y|X = x) \cdot f_X(x) = \\ &= \sum_x \sum_y y \cdot f_{Y|X}(y|x) \cdot f_X(x) = \\ &= \sum_y y \sum_x f_{Y|X}(y|x) \cdot f_X(x) = \\ &= \sum_y y \cdot f_Y(y) = E(Y) \end{aligned} \tag{14}$$