

3 Negativně binomické rozdělení $\text{NegBin}(k, p)$

- Bernoulliho pokusy X_1, X_2, \dots
 - $X_i = 1 \dots$ událost nastala (úspěch); $X_i = 0 \dots$ událost nenastala (neúspěch); $i = 1, 2, \dots$
 - $\Pr(X_i = 1) = p$
 - $\Pr(X_i = 0) = 1 - p = q$
- $X \dots$ počet nastalých úspěchů předcházejících předem stanovenému počtu k neúspěchů
- $X \sim \text{NegBin}(k, p)$
- $\theta = (k, p)$
- pravděpodobnostní funkce
$$p(x) = \binom{x + k - 1}{x} p^x (1 - p)^k \quad x = 1, 2, \dots$$
- vlastnosti: $E[X] = \frac{kp}{1-p}$; $\text{Var}[X] = \frac{kp}{(1-p)^2}$
- `dnbnom(n, k, 1 - p)`, `pnbnom(n, k, 1 - p)`, `rnbnom(M, k, 1 - p)`
- Data:
 - **Dataset 2: Dělníci v továrně**
 - V rámci studie počtu úrazů v továrnách byl zaznamenán počet úrazů u každého dělníka v jedné vybrané továrně během roku 1920. Celkový počet dělníků zahrnutých do studie $M = 647$. Údaje ze studie jsou uvedeny v následující tabulce.

n	0	1	2	3	4	≥ 5	\sum
m_{observed}	447	132	42	21	3	2	647

Příklad 3.1. Pravděpodobnostní funkce negativně binomického modelu

Naprogramujte v  funkci `dNegBinom(x, k, p)` počítající hodnoty pravděpodobnostní funkce negativně binomického rozdělení $\text{NegBin}(k, p)$ v hodnotě x . Správnost funkce otestujte na výpočtu $p(x)$, $x = 0, 1, 2$ pro $X \sim \text{NegBin}(k, p)$, kde $k = 5$ a $p = 0.4$. Výsledky ověřte s výsledky funkce `dnbinom()` dostupné v . Jaký je rozdíl v syntaxích obou funkcí?

Řešení příkladu 3.1

<code>p0</code>	<code>p1</code>	<code>p2</code>
1 0.07776	0.15552	0.186624

1
2

$p(0) = 0.7776$; $p(1) = 0.1555$; $p(2) = 0.1866$.

★

Příklad 3.2. Výpočet pravděpodobností na základě negativně binomického modelu

Pravděpodobnost sestřelení terče dosahuje u biatlonistky Koukalové až 95 %. Pravděpodobnost sestřelení terče u biatlonistky Charvátové se pohybuje okolo 65 %. Porovnejte, jaká je pravděpodobnost, že při tréninku sestřelí každá z biatlonistek před prvními dvěma neúspěchy (a) právě pět terčů; (b) nejvýše deset terčů; (c) alespoň sedm terčů; (d) alespoň patnáct terčů; (e) alespoň 25 terčů.

Řešení příkladu 3.2

	prave	5	nejvyse	10	alespon	7	alespon	15	alespon	25	
Koukalova	0.0116		0.1184	0.9428	0.8108	0.6241					3
Charvatova	0.0853		0.9576	0.1691	0.0098	0.0002					4

3
4
5

Biatlonistka Koukalová při tréninku před prvními dvěma neúspěchy sestřelí s pravděpodobností 1.16 % právě pět terčů, s pravděpodobností 11.84 % nejvýše 10 terčů, s pravděpodobností 94.28 % alespoň 7 terčů, s pravděpodobností 81.08 % alespoň 15 terčů a s pravděpodobností 62.41 % alespoň 25 terčů.

Biatlonistka Charvátová při tréninku před prvními dvěma neúspěchy sestřelí s pravděpodobností 8.53 % právě pět terčů, s pravděpodobností 95.76 % nejvýše 10 terčů, s pravděpodobností 16.91 % alespoň 7 terčů, s pravděpodobností 0.98 % alespoň 15 terčů a s pravděpodobností 0.02 % alespoň 25 terčů. ★

Příklad 3.3. Výpočet očekávaných početností za předpokladu negativně binomického modelu

V příkladu 2.2 jsme popsali počet úrazů u dělníků v továrně pomocí náhodné veličiny X , která pocházela z Poissonova rozdělení s parametrem $\lambda = 0.4652$ odhadnutým na základě dat. Srovnáním pozorovaných početností m_{obs} s očekávanými početnostmi m_{exp} , za podmínky, že $X \sim \text{Poiss}(0.4652)$ jsme diagnostikovali overdisperzi v datech oproti předpokládanému Poissonovu modelu. Hodnoty pozorovaných a očekávaných početností jsou pro připomenutí uvedeny v následující tabulce.

n	0	1	2	3	4	≥ 5	\sum
$m_{observed}$	447	132	42	21	3	2	647
$m_{exp.Poiss}$	406	189	44	7	1	0	647

V případě, že data vykazují po aproximaci Poissonovým rozdělením overdisperzi, bývá vhodné popsat data náhodnou veličinou X pocházející z negativně binomického rozdělení $X \sim \text{NegBin}(k, p)$. Vypočítejte očekávané početnosti výskytu úrazů u dělníků v továrně za předpokladu, že početnosti úrazů pocházejí z negativně binomického rozdělení $\text{NegBin}(k, p)$, kde $\hat{k} = \frac{\widehat{E[X]}^2}{\widehat{\text{Var}[X]} - \widehat{E[X]}}$ a $\hat{p} = 1 - \frac{\widehat{E[X]}}{\widehat{\text{Var}[X]}}$. Výsledné početnosti porovnejte s očekávanými početnostmi za předpokladu Poissonova rozdělení.

Řešení příkladu 3.3

k	p						
1	0.9548138	0.3276139					
0	1	2	3	4	5		
m_{obs}	447	132	42	21	3	2	647
$m_{exp.p}$	406	189	44	7	1	0	647
$m_{exp.n}$	443	139	44	14	5	2	647

6
7
8
9
10
11

Odhad $\hat{k} = 0.9548$, odhad $\hat{p} = 0.3276$.

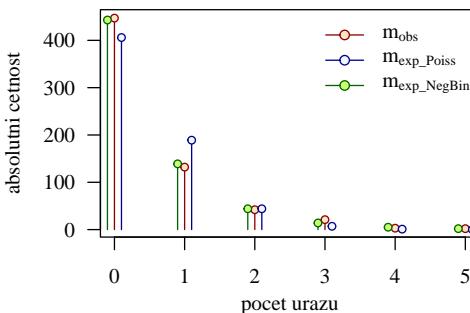
n	0	1	2	3	4	≥ 5	\sum
$m_{observed}$	447	132	42	21	3	2	647
$m_{exp.Poiss}$	406	189	44	7	1	0	647
$m_{exp.NegBin}$	443	139	44	14	5	2	647

Z tabulky vidíme, že očekávané početnosti vypočítané za předpokladu negativně binomického modelu lépe popisují chování pozorovaných početností úrazů u dělníků v továrně než početnosti vypočítané za předpokladu Poissonova modelu. ★

Příklad 3.4. Overdispersion a underdispersion v negativně binomickém modelu

V příkladu 3.3 jsme vypočítali hodnoty očekávaných absolutních početností úrazů dělníků v továrně za podmínky, že data pochází z $\text{NegBin}(k, p)$, kde $k = 0.9548$, $p = 0.3276$. Do jednoho grafu zaneste nyní hodnoty pozorovaných početností m_{observed} , hodnoty očekávaných početností za předpokladu Poissonova rozdělení $m_{\text{exp.Poiss}}$ a hodnoty očekávaných početností za předpokladu negativně binomického rozdělení $m_{\text{exp.NegBin}}$. Na základě výsledného grafu stanovte, zda v případě použití negativně binomického modelu dochází k overdisperzi nebo underdisperzi. Závěr podložte srovnáním rozptylu vypočítaného z pozorovaných dat s rozptylem vypočítaným z očekávaných dat.

Řešení příkladu 3.4



Obrázek 1: Pozorované četnosti a očekávané četnosti za předpokladu negativně binomického a Poissonova modelu

Z vykresleného grafu je zřetelně viditelná blízkost pozorovaných početností a očekávaných početností za předpokladu negativně binomického modelu.

Var.obs	Var.exp.n
1 0.6919002	0.6700035

12
13

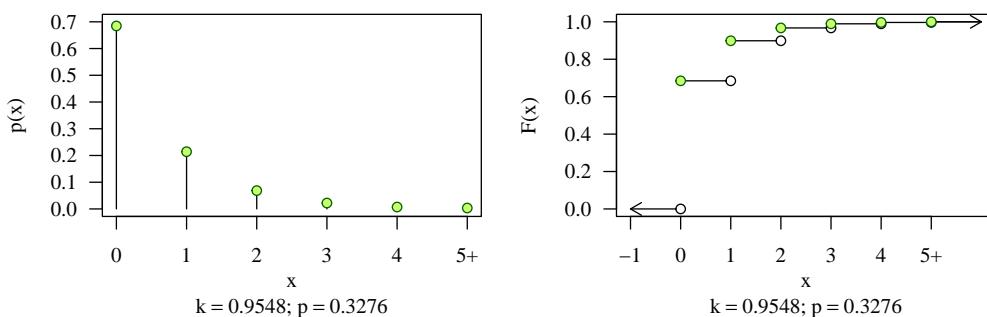
Hodnota rozptylu získaného z pozorovaných dat vyšla 0.6919, hodnota rozptylu získaného z očekávaných dat za předpokladu negativně binomického modelu vyšla 0.6700. Vidíme, že hodnoty rozptylů jsou si velmi blízké. V tomto případě tedy nedochází ani k overdisperzi ani k underdisperzi. Pro srovnání připomeňme, že hodnota rozptylu získaného z očekávaných dat za předpokladu Poissonova modelu vyšla 0.4691 (overdisperze; viz příklad 2.2). ★

Příklad 3.5. Graf pravděpodobnostní a distribuční funkce negativně binomického modelu

V příkladu 3.3 jsme odhadli hodnoty parametrů k a p negativně binomického rozdělení $\text{NegBin}(k, p)$ jako $\hat{k} = 0.9548$, $\hat{p} = 0.3276$. Na základě tohoto rozdělení jsme vypočítali očekávané početnosti výskytu úrazů u dělníků v továrně. Nakreslete graf pravděpodobnostní a distribuční funkce negativně binomického rozdělení $\text{NegBin}(k, p)$, kde $k = 0.9548$, $p = 0.3276$, v hodnotách $x = 0, 1, 2, 3, 4$ a $x \geq 5$.

Řešení příkladu 3.5

★



Obrázek 2: Pravděpodobnostní a distribuční funkce negativně binomického modelu

Příklad 3.6. Výpočet pravděpodobností na základě negativně binomického modelu

Za předpokladu, že náhodná veličina X , udávající počet úrazů u dělníků v továrně, pochází z negativně binomického modelu s parametry $k = 0.9548$ a $p = 0.3276$, tj. $X \sim \text{NegBin}(k, p)$ vypočítejte pravděpodobnost, že u náhodné vybraného dělníka dojde během jednoho roku k (a) nula úrazům; (b) třem nebo čtyřem úrazům; (c) nejvýše dvěma úrazům; (d) alespoň jednomu úrazu. Výsledky porovnejte s pravděpodobnostmi vypočítanými v příkladu 2.6 za předpokladu Poissonova modelu.

Řešení příkladu 3.6

	a	b	c	d
1	0.6845545	0.02929255	0.9672589	0.3154455

14
15

Pravděpodobnost, že u vybraného dělníka nedojde během roku k žádnému úrazu, je 68.46 %. Pravděpodobnost, že u vybraného dělníka dojde během roku k třem nebo čtyřem úrazům, je 2.93 %. Pravděpodobnost, že u vybraného dělníka dojde během roku k nejvýše dvěma úrazům, je 96.73 %. Pravděpodobnost, že u vybraného dělníka dojde během roku k alespoň jednomu úrazu, je 31.54 %.

	počet úrazů	žádný	tři nebo čtyři	nejvýše dva	alespoň jeden
NegBin		0.6846	0.0293	0.9673	0.3154
Poiss		0.6280	0.0118	0.9881	0.3720

★

Příklad 3.7. Střední hodnota a rozptyl náhodné veličiny z negativně binomického modelu

Za předpokladu, že náhodná veličina X , udávající počet úrazů u dělníků v továrně, pochází z negativně binomického rozdělení, tj. $X \sim \text{NegBin}(k, p)$, s parametry $k = 0.9548$, $p = 0.3276$, vypočítejte střední hodnotu $E[X]$ a rozptyl $\text{Var}[X]$ náhodné veličiny X . Střední hodnotu a rozptyl porovnejte s jejich odhady vypočítanými na (a) základě očekávaných dat; (b) na základě pozorovaných dat (viz příklad 3.3). Výsledky porovnejte s pravděpodobnostmi vypočítanými za předpokladu Poissonova modelu $\text{Poiss}(\lambda)$, kde $\lambda = 0.4652$.

Řešení příkladu 3.7

	E.X	Var.X	E.exp	Var.exp	E.obs	Var.obs
1	0.4652241	0.6919002	0.4621329	0.6700035	0.4652241	0.6919002

16
17

Střední hodnota počtu úrazů dělníků v továrně je 0.4652 s rozptylem 0.6919, odhad střední hodnoty počtu úrazů dělníků v továrně vypočítaný na základě očekávaných hodnot je 0.4652 s rozptylem 0.6919. Odhad střední hodnoty počtu úrazů dělníků v továrně vypočítaný na základě pozorovaných dat je 0.4621 s rozptylem 0.6700.

Tabulka 1: Porovnání odhadu střední hodnoty $E[X]$ a rozptylu $\text{Var}[X]$ (a) z pozorovaných dat; (b) z očekávaných dat za předpokladu, že $X \sim \text{NegBin}(k, p)$; (c) z očekávaných dat za předpokladu, že $X \sim \text{Poiss}(\lambda)$

	$\widehat{E[X]}$	$\widehat{\text{Var}[X]}$
pozorovaná data	0.4652	0.6919
očekávaná - NegBin	0.4652	0.6700
očekávaná data - Poiss	0.4668	0.4691

★

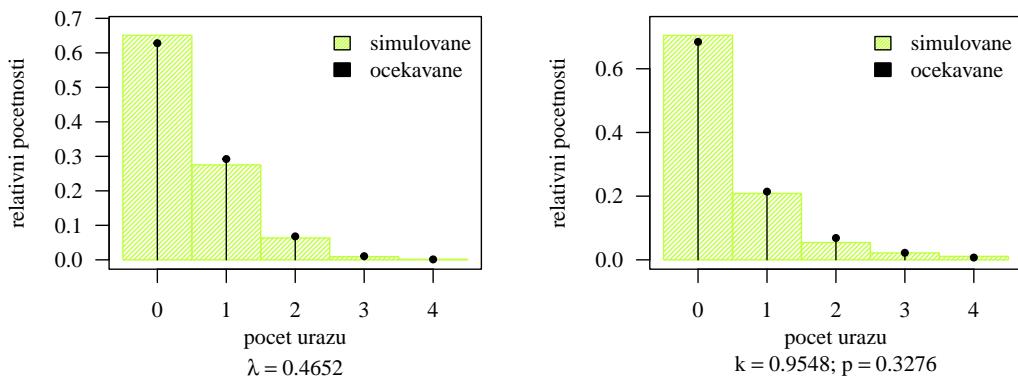
Příklad 3.8. Simulační studie pro negativně binomický model a Poissonův model

Vytvořte simulační studii modelující chování očekávaných početností náhodné veličiny X popisující počet úrazů dělníků v továrně za předpokladu, že

- (a) $X \sim \text{Poiss}(\lambda)$, kde $\lambda = 0.4652$,
- (b) $X \sim \text{NegBin}(k, p)$, kde $k = 0.9548$ a $p = 0.3276$.

Vygenerujte pseudonáhodná čísla X (početnosti úspěchů) opakovaná M -krát ($M = 647$) pocházející (a) z Poissonova rozdělení, tj. $X \sim \text{Poiss}(\lambda)$; (b) z negativně binomického rozdělení, tj. $X \sim \text{NegBin}(k, p)$. Pro každé rozdělení vytvořte histogram vygenerovaných pseudonáhodných čísel a superponujte jej hodnotami očekávaných (teoretických početností).

Řešení příkladu 3.8



Obrázek 3: Porovnání pozorovaných četností a očekávaných četností za předpokladu (a) Poissonova modelu (vlevo); (b) negativně binomického modelu (vpravo)

