

# 1 Binomické rozdělení $\text{Bin}(N, p)$

- Bernoulliho pokusy  $X_1, \dots, X_N$ 
  - $X_i = 1 \dots$  událost nastala;  $X_i = 0 \dots$  událost nenastala;  $i = 1, \dots, N$
  - $\Pr(X_i = 1) = p$
  - $\Pr(X_i = 0) = 1 - p = q$
- $X \dots$  počet událostí v posloupnosti  $N$  nezávislých Bernoulliho pokusů, přičemž pravděpodobnost nastání události v každém pokusu je vyjádřena parametrem  $p$
- $\sum_{i=1}^N X_i = X \sim \text{Bin}(N, p)$
- $\theta = (N, p)$
- pravděpodobnostní funkce
$$p(x) = \binom{N}{x} p^x (1-p)^{N-x} \quad x = 0, 1, \dots, N$$
- vlastnosti:  $E[X] = Np$ ;  $\text{Var}[X] = Np(1-p)$
- `dbinom(x, N, p)`, `pbinom(x, N, p)`, `rbinom(M, N, p)`
- Data:
  - **Dataset 1: Počet chlapců v rodinách s 12 dětmi**
  - V rámci studie poměru pohlaví u lidí z roku 1889 bylo na základě záznamů z nemocnic v Sasku zaznamenáno rozdělení počtu chlapců v čtrnáctičlenných rodinách. Mezi  $M = 6115$  rodinami s  $N = 12$  dětmi byla pozorována početnost chlapců. Údaje ze studie jsou uvedeny v následující tabulce.

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12	$\sum$
$m_{\text{observed}}$	3	24	104	286	670	1033	1343	1112	829	478	181	45	7	6115

## Příklad 1.1. Výpočet očekávaných početností za předpokladu binomického modelu

Vezměte údaje z **datasetu 1**. Vypočítejte očekávané početnosti výskytu chlapců  $m_{\text{expected}}$  za předpokladu, že početnosti chlapců  $X$  v rodinách mají binomické rozdělení  $\text{Bin}(N, p)$  s parametry  $N = 12$  a

$$\hat{p} = \frac{\sum_{n=0}^N nm_{\text{observed}}}{NM}. \quad (1.1)$$

### Řešení příkladu 1.1

Odhad parametru  $p$ , tj.  $\hat{p} = 0.5192$ . Tabulka očekávaných početností  $m_{\text{expected}}$  je

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12	$\sum$
$m_{\text{expected}}$	1	12	72	258	628	1085	1367	1266	854	410	133	26	2	6114

Z tabulky očekávaných početností vidíme, že součet očekávaných početností dává výsledek  $M = 6114$ . Odchylka od původní hodnoty  $M = 6115$  je způsobena přesným výpočtem očekávaných početností a jejich následným zaokrouhlením. Konkrétně v tomto případě, pokud bychom očekávané početnosti spočítali na základě binomického rozdělení  $\text{Bin}(N, p)$ , kde  $N = 12$  a  $\hat{p} = 0.5192$  (hodnotu  $\hat{p}$  bychom pro další výpočet zaokrouhlili na čtyři desetinná místa) dostali bychom následující tabulkou očekávaných početností.


$n$	0	1	2	3	4	5	6	7	8	9	10	11	12	$\sum$
$m_{\text{expected}}$	1	12	72	259	628	1085	1367	1266	854	410	133	26	2	6115

Při použití hodnoty odhadu  $\hat{p}$  zaokrouhlené na čtyři desetinná místa došlo k mírné úpravě binomického rozdělení a očekávaná početnost výskytu tří chlapců v rodině se z hodnoty 258.47 přehoupla na hodnotu 258.52, čímž jsme po zaokrouhlení získali absolutní početnost 259 namísto 258. Ostatní očekávané početnosti zůstaly nezměněny, jelikož jejich nezaokrouhlená hodnota byla dostatečně blízko k celému číslu. ★

### Příklad 1.2. Overdispersion a underdispersion v binomickém modelu

V předchozím příkladu 1.1 jsme stanovili očekávané početnosti výskytu chlapců v rodinách s dvanácti dětmi. Do jednoho grafu zaneste nyní hodnoty pozorovaných početností  $m_{observed}$  a hodnoty očekávaných početností  $m_{expected}$ . Pozorované a očekávané početnosti od sebe barevně odlište. Na základě výsledného grafu stanovte, zda došlo v tomto případě k overdisperzi nebo underdisperzi. Závěr podložte srovnáním rozptylu vypočítaného z pozorovaných dat s rozptylem vypočítaným z očekávaných dat.

#### Řešení příkladu 1.2



Obrázek 1: Porovnání pozorovaných a očekávaných početností v binomickém modelu

Oproti očekávaným početnostem jsou pozorované početnosti krajních případů vyšší a naopak pozorované početnosti nejčastějších případů jsou nižší. Tato situace ukazuje na vyšší rozptyl pozorovaných početností než teoretických. Jde tedy o .....disperzi.

var.obs	var.exp
1 3.48984	2 2.995539


1  
2

Rozptyl skutečných počtů chlapců v rodinách s dvanácti dětmi je 3.4898, rozptyl očekávaných počtů chlapců je 2.9956. Rozptyl skutečných počtů je tedy vyšší než rozptyl očekávaných počtů chlapců v rodinách s dvanácti dětmi. ★

### Příklad 1.3. Graf pravděpodobnostní a distribuční funkce binomického modelu

V příkladu 1.1 jsme odhadli hodnotu parametru  $p$  binomického rozdělení  $\text{Bin}(N, p)$  jako  $\hat{p} = 0.5192$ . Hodnota parametru  $N = 12$ . Nakreslete graf pravděpodobnostní a distribuční funkce binomického rozdělení  $\text{Bin}(N, p)$ , kde  $N = 12$  a  $p = 0.5192$ .

#### Řešení příkladu 1.3



Obrázek 2: Pravděpodobnostní a distribuční funkce binomického modelu

★

#### Příklad 1.4. Výpočet pravděpodobností na základě binomického modelu

Za předpokladu, že náhodná veličina  $X$ , udávající počet chlapců v rodině s dvanácti dětmi, pochází z binomického rozdělení, tj.  $X \sim \text{Bin}(N, p)$ , s parametry  $N = 12$  a  $p = 0.5192$ , vypočítejte pravděpodobnost, že v rodině s dvanácti dětmi bude (a) právě devět chlapců; (b) nejvýše čtyři chlapci; (c) alespoň osm chlapců; (d) čtyři, pět, šest, nebo sedm chlapců.

#### Řešení příkladu 1.4

	a	b	c	d
1	0.06703911	0.1588736	0.2330869	0.7107605

3

4

Pravděpodobnost, že v rodině bude právě devět chlapců, je 6.7 %. Pravděpodobnost, že v rodině budou nejvýše čtyři chlapci, je 15.89 %. Pravděpodobnost, že v rodině bude alespoň osm chlapců, je 23.31 %. Pravděpodobnost, že v rodině bude čtyři, pět, šest, nebo sedm chlapců, je 71.08 %. ★

#### Příklad 1.5. Střední hodnota a rozptyl náhodné veličiny z binomického modelu

Za předpokladu, že náhodná veličina  $X$ , udávající počet chlapců v rodině s dvanácti dětmi, pochází z binomického rozdělení, tj.  $X \sim \text{Bin}(N, p)$ , s parametry  $N = 12$  a  $p = 0.5192$ , 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 1.2).

#### Řešení příkladu 1.5

	E.X	Var.X	E.exp	Var.exp	E.obs	Var.obs
1	6.2304	2.995576	6.229926	2.995539	6.230581	3.48984

5

6


Střední hodnota počtu chlapců v rodině s dvanácti dětmi je 6.2304 s rozptylem 2.9956. Odhad střední hodnoty počtu chlapců v rodině vypočítaný na základě očekávaných hodnot je 6.2299 s rozptylem 2.9955. Odhad střední hodnoty počtu chlapců v rodině vypočítaný na základě pozorovaných dat je 6.2306 s rozptylem 3.4898. ★

#### Příklad 1.6. Simulační studie pro binomický model

Sekci o binomickém rozdělení zakončíme simulační studií modelující chování očekávaných početností náhodné veličiny  $X$  ... počet chlapců v rodinách s dvanácti dětmi za předpokladu, že  $X \sim \text{Bin}(N, p)$ ,  $N = 12$ ,  $p = 0.5192$ .

Vygenerujte pseudonáhodná čísla  $X$  (početnosti úspěchů) opakovaná  $M$ -krát ( $M = 6115$ ) z  $\text{Bin}(N, p)$ , kde  $N = 12$  a  $p = 0.5192$ . Vytvořte histogram vygenerovaných pseudonáhodných čísel superponovaný hodnotami očekávaných (teoretických) početností za předpokladu, že  $X \sim \text{Bin}(N, p)$ .

#### Řešení příkladu 1.6



Obrázek 3: Porovnání pozorovaných a očekávaných početností v binomickém modelu ★