

5. cvičení z STP

18. března 2021

Poznámky k binomickému rozdělení: Mějme n nezávislých opakování daného pokusu, jehož úspěšnost je $0 < p < 1$. Veličina

$X = \text{“počet úspěchů během } n \text{ pokusů”}$

s hodnotami $X \in \{0, 1, \dots, n\}$ má pak tzv. *binomické* rozdělení $\text{Bi}(n, p)$. Pro $k = 0, 1, \dots, n$ pak je

$$P(X = k) = \binom{n}{k} p^k \cdot (1 - p)^{n-k}$$

což je jeden z členů v binomické větě (odtud také ten název): $(a + b)^n = \sum_{k=0}^n \binom{n}{k} a^k \cdot b^{n-k}$

Důvod, proč tu máme kombinační číslo, je v tom, že daných k úspěchů je rozmístěno mezi n pokusy právě $\binom{n}{k}$ způsoby.

Příklad 5.1 *Pravděpodobnost, že atlet v oddíle skočí do dálky přes 5 m, je 0.7. V oddíle je 6 atletů.*

(a) *Určete rozdělení náhodné veličiny*

$$X = \begin{cases} 1, & \text{atlet skočil přes 5 m} \\ 0, & \text{atlet neskočil přes 5 m,} \end{cases}$$

její střední hodnotu $E(X)$ a rozptyl $\text{var}(X)$.

(b) *Určete rozdělení náhodné veličiny*

$$Y = \text{“počet atletů v oddíle, kteří skočili přes 5 m”}$$

její střední hodnotu $E(Y)$ a rozptyl $\text{var}(Y)$.

(c) *Jaká je pravděpodobnost, že přes 5 m skočí v oddíle alespoň 4 atleti?*

Řešení:

(a) Veličina X má *alternativní* rozdělení, tj. $X \sim \text{Alt}(p)$, kde $p = P(X = 1) = 0.7$ je pravděpodobnost úspěšného pokusu a $P(X = 0) = 1 - p = 0.3$.

A dále máme

$$E(X) = \sum_{i \in \mathbb{R}} i \cdot P(X = i) = 0 \cdot (1 - p) + 1 \cdot p = p = 0.7$$

$$E(X^2) = \sum_{i \in \mathbb{R}} i^2 \cdot P(X = i) = 0^2 \cdot (1 - p) + 1^2 \cdot p = p = 0.7$$

a

$$\text{var}(X) = E(X^2) - (E(X))^2 = p - p^2 = p(1 - p) = 0.7 \cdot 0.3 = 0.21 .$$

- (b) Veličina Y představuje počet úspěchů při $n = 6$ nezávislých pokusech, s pravděpodobností úspěchu $p = 0.7$, takže Y má *binomické rozdělení* $\text{Binom}(n, p)$. Hodnoty veličiny Y jsou $k = 0, 1, \dots, n$ a jejich pravděpodobnosti jsou

$$P(Y = k) = \binom{n}{k} p^k (1-p)^{n-k} = \binom{6}{k} 0.7^k \cdot 0.3^{6-k}.$$

Pro další výpočty se hodí všimnout si, že $Y = \sum_{i=1}^n X_i$ kde

$$X_i = \begin{cases} 1, & i\text{-tý atlet skočil přes 5 m} \\ 0, & i\text{-tý atlet neskočil přes 5 m,} \end{cases}$$

jsou navzájem nezávislé náhodné veličiny a $X_i \sim \text{Alt}(p)$.

Pro střední hodnotu veličiny Y pak máme

$$E(Y) = E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \underbrace{E(X_i)}_p = n \cdot p = 6 \cdot 0.7 = 4.2$$

a z nezávislosti X_i pak pro rozptyl máme

$$\text{var}(Y) = \sum_{i=1}^n \underbrace{\text{var}(X_i)}_{p(1-p)} = np(1-p) = 6 \cdot 0.7 \cdot 0.3 = 1.26.$$

(c)

$$\begin{aligned} P(Y \geq 4) &= \sum_{k=4}^6 \binom{6}{k} 0.7^k \cdot 0.3^{6-k} = 15 \cdot 0.7^4 \cdot 0.3^2 + 6 \cdot 0.7^5 \cdot 0.3^1 + 1 \cdot 0.7^6 \cdot 1 = \\ &= 0.324135 + 0.302526 + 0.117649 = 0.74431. \end{aligned}$$

Příklad 5.2 Semena mají klíčivost $p \in (0, 1)$. Jaký je optimální počet n semen v jamce, aby byla co nejvyšší pravděpodobnost, že vyklíčí právě jedno? Řešte obecně a pro $p = 1/3$.

Řešení:

Vyklíčení jednotlivých semen pokládáme za nezávislé jevy, takže veličina

$$X = \text{“počet vyklíčených semen z } n \text{ semen v jamce”}$$

má binomické rozdělení $\text{Bi}(n, p)$. Hledáme teď $n \in \mathbb{N}$ ($n \geq 1$), které maximalizuje funkci

$$g(n) = P(X = 1) = \binom{n}{1} p^1 (1-p)^{n-1} = np(1-p)^{n-1} \left(= np \cdot e^{(n-1) \ln(1-p)} \right).$$

Pro vyšetření této funkce můžeme uvažovat n jako reálnou proměnnou v intervalu $(0, +\infty)$, abychom pak mohli využít derivaci (podle n) a to především pro zjištění, kde je funkce g rostoucí a kde klesající:

$$g'(n) = p(1-p)^{n-1} + np(1-p)^{n-1} \ln(1-p) = p(1-p)^{n-1} (1 + n \ln(1-p)).$$

Dostáváme tak, že g je rostoucí až do bodu $n = \frac{-1}{\ln(1-p)}$ a pak je klesající. V uvedeném bodě tak nastává maximum v rámci reálné proměnné. Maximum v oboru přirozených čísel \mathbb{N} nastává pro jedno

(nebo obě) ze dvou celých čísel, která jsou nejbližší hodnotě $\frac{-1}{\ln(1-p)}$. Zjistit, které z těchto dvou čísel to vlastně obecně je, ale už dá více práce.

Pro $p = \frac{1}{3}$ máme $\frac{-1}{\ln(1-p)} = \frac{-1}{\ln(2/3)} \doteq 2.466$. Nejbližší čísla jsou tedy 2 a 3 a v nich stačí porovnat hodnoty funkce g :

$$g(2) = 2 \cdot \frac{1}{3} \left(\frac{2}{3}\right)^1 = \frac{4}{9}$$

$$g(3) = 3 \cdot \frac{1}{3} \left(\frac{2}{3}\right)^2 = \frac{4}{9}$$

Obě možnosti 2 a 3 tedy představují optimální počty semen pro $p = \frac{1}{3}$.

Poznámka: Pro $p \rightarrow 0$ je $\ln(1-p) \approx -p$ a $n \approx 1/p$, což je v souladu s očekáváním. Pro $p \rightarrow 1$ vychází $n \rightarrow 0$, což vypadá překvapivě. Znamená to ale jen, že funkce g je na množině přirozených čísel klesající a maxima nabývá v 1.

Zde je ještě (pro zájemce) podrobnější a úplné řešení:

Příklad se dá řešit ještě jinak a (překvapivě) i jednodušeji (ale zápis je delší). Zřejmě pro $n \in \mathbb{N}$ máme

$$g(n) \leq g(n+1) \Leftrightarrow 1 \leq \frac{g(n+1)}{g(n)} = \frac{(n+1)p(1-p)^n}{np(1-p)^{n-1}} = \frac{n+1}{n}(1-p)$$

což po úpravě dává

$$\frac{1}{1-p} \leq \frac{n+1}{n} = 1 + \frac{1}{n}$$

$$\underbrace{\frac{1}{1-p} - 1}_{\frac{p}{1-p}} \leq \frac{1}{n}$$

a nakonec

$$n \leq \frac{1-p}{p} = \frac{1}{p} - 1.$$

Speciálně vidíme, že to samé platí i pro ostré nerovnosti, tj.

* $g(n) < g(n+1)$ platí právě když $n < \frac{1}{p} - 1$.

* $g(n) > g(n+1)$ platí právě když $n > \frac{1}{p} - 1$.

* $g(n) = g(n+1)$ platí právě když $n = \frac{1}{p} - 1$.

Odsud ihned máme, že

- pro $\frac{1}{p} - 1 < 1$, tj. $p \in (\frac{1}{2}, 1)$ je g ostře klesající (na \mathbb{N}), takže maximum nastává pro $n_0 = 1$ a pravděpodobnost pak je $P(X=1) = g(1) = p$.

- pokud $\frac{1}{p} \notin \mathbb{N}$ a $p \in (0, \frac{1}{2})$, budou všechny nerovnosti mezi hodnotami funkce g ostré a největší hodnota bude dosažena pro $n_0 = \left\lceil \frac{1}{p} \right\rceil$ (tj. celá část z $\frac{1}{p}$).

Je to proto, že z $n_0 - 1 < \frac{1}{p} - 1$ plyne $g(n_0 - 1) < g(n_0)$ a současně z $\frac{1}{p} - 1 < n_0$ plyne $g(n_0) > g(n_0 + 1)$.

Navíc ještě z nerovnosti $n_0 < \frac{1}{p} < n_0 + 1$ dostaneme odhad pravděpodobnosti

$$\underbrace{\left(\frac{1}{p} - 1\right) p(1-p)^{\frac{1}{p}-1}}_{(1-p)^{\frac{1}{p}}} < \underbrace{n_0 p(1-p)^{n_0-1}}_{P(X=1)} < \underbrace{\frac{1}{p} p(1-p)^{\frac{1}{p}-2}}_{(1-p)^{\frac{1}{p}-2}}$$

- a konečně pro $n_0 = \frac{1}{p} \in \mathbb{N}$ budou všechny nerovnosti mezi hodnotami $g(n)$ také ostré až na případ $g(n_0 - 1) = g(n_0)$, který odpovídá maximu funkce g na přirozených číslech.

V tomto případě totiž platí, že $n_0 - 1 = \frac{1}{p} - 1$, tedy skutečně $g(n_0 - 1) = g(n_0)$.

Tedy maximum nastává pro dva počty semen $n_0 - 1$ a n_0 a pravděpodobnost vyklíčení právě jednoho semene je

$$P(X=1) = \frac{1}{p} p(1-p)^{\frac{1}{p}-1} = (1-p)^{\frac{1}{p}-1}$$

Mimo jiné z tohoto všeho vidíme, že pro $p \rightarrow 0$ se pravděpodobnost vyklíčení jednoho semene (při optimálním počtu semen) blíží k $e^{-1} \doteq 0.3679$ (protože $\lim_{p \rightarrow 0^+} (1-p)^{\frac{1}{p}} = \lim_{p \rightarrow 0^+} e^{\frac{\ln(1-p)}{p}} = e^{-1}$).

Pro konkrétní volbu $p = \frac{1}{3}$ máme $\frac{1}{p} = 3 \in \mathbb{N}$ (tedy třetí případ) a tak opět dostáváme, že: optimální počet semen je $n \in \left\{ \frac{1}{p} - 1, \frac{1}{p} \right\} = \{2, 3\}$ a pravděpodobnost bude $P(X = 1) = (1-p)^{\frac{1}{p}-1} = \frac{4}{9}$.

Připomenutí: Veličina

$X =$ “počet neúspěchů než nastane první úspěch”

má geometrické rozdělení $\text{Geom}(p)$, pokud můžeme opakovat libovolné množství nezávislých pokusů, které mají všechny stejnou pravděpodobnost úspěchu p . Příkladem je třeba situace, že se chceme trefit míčem do koše apod.

Hodnoty veličiny X jsou $\{0, 1, 2, \dots\}$. Pro odvození rozdělení X si pro $i = 1, 2, 3, \dots$ označme jevy

$A_i =$ “ i -tý pokus je úspěšný”

kteří budou nezávislé s budou mít pravděpodobnosti $P(A_i) = p$. Pak máme pravděpodobnosti

$$P(X = k) = P(A_1^c \cap \dots \cap A_k^c \cap A_{k+1}) = P(A_1^c) \cdot \dots \cdot P(A_k^c) \cdot P(A_{k+1}) = (1-p)^k p$$

pro $k = 0, 1, 2, \dots$. Pro střední hodnotu a rozptyl pak máme:

$$E(X) = \sum_{k=0}^{\infty} k \cdot P(X = k) = \sum_{k=0}^{\infty} kp(1-p)^k = \dots = \frac{1-p}{p}$$

$$\text{var}(X) = \frac{1-p}{p^2}$$

což si můžeme lépe zapamatovat jako

$$\text{var}(X) = \frac{1}{p} \cdot E(X) .$$

Příklad 5.3 *Pravděpodobnost narození chlapce je 0.51. Jaká je pravděpodobnost, že v dané porodnici dnes bylo nejpozději (v časovém pořadí) čtvrté narozené dítě holka?*

Řešení:

Lze použít dva přístupy:

(a) Vezmeme si náhodnou veličinu

$X =$ “počet narozených chlapců před první narozenou holkou.”

Ta má *geometrické* rozdělení $\text{Geom}(p)$ s pravděpodobností $p = 1 - 0.51 = 0.49$ úspěšného pokusu (tj. narození holky). Hodnoty veličiny X jsou $k = 0, 1, 2, \dots$ s pravděpodobnostmi

$$P(X = k) = (1-p)^k \cdot p = 0.51^k \cdot 0.49$$

Pro jednodušší výpočet si ještě označme $q = 1 - p = 0.51$. Hledaná pravděpodobnost je tedy

$$P(X < 4) = \sum_{k=0}^3 q^k \cdot (1-q) = (1-q) \cdot \underbrace{(1+q+\dots+q^3)}_{\frac{1-q^4}{1-q}} = 1 - q^4 = 1 - 0.51^4 \doteq 0.9323.$$

(b) Vezmeme si náhodnou veličinu

$Y =$ “počet narozených holek mezi prvními 4 narozenými dětmi.”

Ta má binomické rozdělení $\text{Bi}(4, p)$, kde je opět $p = 0.49$. Hledaná pravděpodobnost je tedy

$$P(Y \geq 1) = 1 - P(Y = 0) = 1 - \binom{4}{0} p^0 \cdot (1 - p)^4 = 1 - q^4 = 1 - 0.51^4.$$