

## 11. cvičení z PSt — 2.–6.5.2022

Ve většině příkladů je potřeba vyčíslit distribuční funkce (nebo jejich inverzní funkce) v konkrétních bodech. Pokud k tomu nemáte po ruce vhodné počítadlo, můžete výsledek nechat nevyčíslený. Zábavnější ale bude skutečně dosadit. Nejlépe pomocí R (viz níže), ale můžete použít i např. <https://www.wolframalpha.com> nebo vhodné tabulky online, např. [https://en.wikipedia.org/wiki/Student%27s\\_t-distribution#Table\\_of\\_selected\\_values](https://en.wikipedia.org/wiki/Student%27s_t-distribution#Table_of_selected_values).

### Vhodné funkce R

- **pnorm(q,mean,sd)** distribuční funkce normálního rozdělení v bodě  $q$ . Pokud se parametry nevedou, je  $mean = 0$ ,  $sd = 1$ , tj. standardní normální rozdělení. Pozor, uvádí se směrodatná odchylka, ne rozptyl!
- **qnorm(p,mean,sd)** inverzní distribuční funkce (kvantilová funkce, quantile function) normálního rozdělení v bodě  $p$ : pro jaké  $q$  je distribuční funkce rovna  $p$ ?
- **rnorm(n,mean,sd)** vygeneruje  $n$  čísel z  $N(mean, sd^2)$
- **dnorm(x,mean,sd)** hustota (density) v bodě  $x$
- pro kontrolu **qnorm(1)–qnorm(-1)  $\doteq$  0.68**, **qnorm(0.5) = 0**, **pnorm(0) = 0.5**
- pro ostatní distribuce jsou také k dispozici funkce s prvním písmenkem  $p$ ,  $q$ ,  $r$ ,  $d$
- zejména se nám budou hodit **dbinom**, **dgeom**, **dpois**, **dt**, **dunif**, **dexp**.

### Totéž v Pythonu

- **from scipy.stats import norm**
- **norm.cdf()**, **norm.pdf()**, **norm.ppf()** (kvantilová funkce, „percent point function“, **norm.rvs()** (generování náhodných čísel)
- analogicky pro další rozdělení: **binom**, **geom**, **poisson**, **expon**, atd.

### Připomenutí teorie

- Čebyševova nerovnost: Nechť  $X$  má konečnou střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ . Pak

$$P(|X - \mu| \geq a \cdot \sigma) \leq \frac{1}{a^2}.$$

- Centrální limitní věta: Nechť  $X_1, \dots, X_n$  jsou stejně rozdělené n.n.v. se střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ . Označme  $Y_n = ((X_1 + \dots + X_n) - n\mu)/(\sqrt{n} \cdot \sigma)$ . Pak  $Y_n \xrightarrow{d} N(0, 1)$ . Neboli

$$\lim_{n \rightarrow \infty} F_{Y_n}(x) = \Phi(x) \quad \text{pro každé } x \in \mathbb{R}.$$

Říkáme, že posloupnost  $Y_n$  konverguje k  $N(0, 1)$  v distribuci (*in distribution*).

- De Moivre–Laplaceho věta říká o něco silnější věc: v okolí  $pn$  je i pravděpodobnostní funkce  $Bin(n, p)$  dobře aproximována hustotou  $N(np, np(1-p))$ , tedy vhodně přeškálovanou Gaussovou funkcí  $\varphi$ . Přesněji:

$$\binom{n}{k} p^k (1-p)^{n-k} \simeq \frac{1}{\sqrt{2\pi np(1-p)}} e^{-\frac{(k-np)^2}{2np(1-p)}}$$

pro  $k$  blízké  $pn$ . Ještě přesněji: pokud pro nějaké  $c$  je  $|k - np| < c\sqrt{np(1-p)}$  a  $n$  se blíží nekonečnu, tak poměr dvou výrazů nahoře se blíží k jedné.

## Aplikace nerovností a Centrální Limitní Věty

1. Statistik chce odhadnout průměrnou výšku  $h$  (v metrech) lidí v nějaké populaci, pomocí  $n$  nezávislých vzorků  $X_1, \dots, X_n$ , které vybíráme uniformně náhodně ze všech možných lidí. Pro odhad použije výběrový průměr  $\bar{X}_n = (X_1 + \dots + X_n)/n$ . Odhaduje, že směrodatná odchylka jednoho měření je nejvýše 1 metr.

(a) Jak velké  $n$  má volit, aby směrodatná odchylka  $\bar{X}_n$  byla nejvýše 1 cm?

(b) Pro jaké  $n$  zajistí Čebyševova nerovnost, že pravděpodobnost, že  $\bar{X}_n$  se liší od  $h$  nejvýše o 5 cm s pravděpodobností alespoň 99 %?

(c) Statistik si všimne, že všichni měření lidí mají výšku v intervalu (1.4, 2.1). Jak má upravit odhad směrodatné odchylky? Jak se změní odpovědi na předchozí otázky?

2. Označme  $S = \sum_{k=0}^{30} \binom{100}{k}$ . Označme dále  $X = \sum_{i=1}^{100} X_i$ , kde  $X_i$  je 0 nebo 1, obojí s pravděpodobností 1/2 a veličiny  $X_1, \dots, X_n$  jsou nezávislé. Je tedy  $X \sim \text{Bin}(100, 1/2)$ .

(a) Vyjádřete  $S$  pomocí distribuční funkce  $F_X$ .

(b) Použijte CLV na odhad této pravděpodobnosti.

(c) Případně vyčíslíte  $S$  vhodným softwarem a srovnajte.

3. Odhadněte  $\binom{100}{30}$  pomocí CLV. Nápověda: použijte CLV pro odhad  $P(29.5 < X < 30.5)$  pro vhodnou n.v.  $X$ . Na druhou stranu pro  $P(X = 30)$  máme vzorec  $\binom{100}{30}/2^{100}$  z binomického rozdělení. Alternativně, můžete použít Moivre–Laplaceho větu.

4. Chceme odhadnout, zda naše mince (a způsob jak s ní házíme) je spravedlivá. Pokud ze sta hodů padne orel více než 55-krát, řekneme, že spravedlivá není. Jaká je pravděpodobnost, že se zmýlíme?

## Intervalové odhady

5. Máme jedno měření  $X \sim N(\mu, 1)$ . (Tj. parametr  $\vartheta = \mu$ .)

(a) Najděte intervalový odhad pro  $\mu$  se spolehlivostí 95 %.

(b) Místo jednoho měření jich provedeme  $n$  (pochopitelně nezávislých). Jaký bude teď intervalový odhad pro  $\mu$ ?

(c) Nechť  $X$  má stále střední hodnotu  $\mu$  a rozptyl 1, ale není už nutně normální. Co se změní?