

Úvod do R, pravděpodobnostní rozdělení a limitní věty

Úvodní nastavení. Na disku H si založte adresář na toto cvičení, např. NSTP097. Ze stránky www.karlin.mff.cuni.cz/~dosla/education/ si stáhněte soubory `uvod.R` a `cviceni1.R`.

Otevřete si program R a pomocí File/Open script... si načtete do R soubor `uvod.R`. Odtud budeme postupně společně spouštět jednotlivé příkazy pomocí CTRL+R. Kdo už s R **umí pracovat**, tak může řešit jednotlivé úkoly **samostatně** a nemusí tyto soubory používat.

Nejprve se s pomocí kódu v `uvod.R` ve stručnosti seznámíme s tím, jak provádět některé základní operace v R (přiřazení do proměnné, práce s vektory apod.). Řešení následujících úkolů najdete v souboru `cviceni1.R`.

Úloha 1: Hustoty a distribuční funkce. R má zabudované funkce pro výpočet hustot, distribučních funkcí a kvantilových funkcí pro řadu běžných rozdělení. Taktéž umí generovat náhodné výběry z těchto rozdělení.

Například pro exponenciální rozdělení $\text{Exp}(\lambda)$:

- `dexp(x,lambda)` počítá hustotu v bodě x nebo ve vektoru bodů x ,
- `pexp(x,lambda)` počítá distribuční funkci v bodě x nebo ve vektoru bodů x ,
- `rexp(n,lambda)` generuje náhodný výběr o rozsahu n ,
- `qexp(p,lambda)` počítá hodnotu kvantilové funkce v bodě p

- (a) Nakreslete hustotu rozdělení $\text{Exp}(4)$.
- (b) Nakreslete graf distribuční funkce $\text{Exp}(4)$.
- (c) Vygenerujte náhodný výběr o délce 25 pozorování z $\text{Exp}(4)$.
 - Nakreslete si histogram tohoto výběru a porovnejte s hustotou z bodu a).
 - Spočtete průměr z tohoto výběru a porovnejte jej se střední hodnotou rozdělení $\text{Exp}(4)$. Čemu je rovna střední hodnota rozdělení $\text{Exp}(\lambda)$?
- (d) Zopakujte tento postup pro další rozdělení: $N(0,1)$, $N(-2,4)$, $\Gamma(2,0.5)$, $\Gamma(0.5,0.1)$, $C(0,1)$. Hustoty, distribuční funkce, a náhodné výběry dostaneme takto:
 - $N(\mu, \sigma^2)$ Hustota: `dnorm(x,mi,sigma)` (Pozor! `sigma` je $\sqrt{\sigma^2}$)
 - D.f: `pnorm(x,mi,sigma)`
 - Náh. výběr: `rnorm(n,mi,sigma)`
 - $\Gamma(a, p)$ Hustota: `dgamma(x,rate=a,shape=p)`
 - D.f: `pgamma(x,rate=a,shape=p)`
 - Náh. výběr: `rgamma(n,rate=a,shape=p)`
 - $C(a, b)$ Hustota: `dcauchy(x,a,b)`
 - D.f: `pcauchy(x,a,b)`
 - Náh. výběr: `rcauchy(n,a,b)`

(Poznámka: podobně jako u exponenciálního rozdělení ještě existují funkce `qnorm`, `qgamma`, `atd`, které počítají kvantily.)

- (e) Cauchyho rozdělení je známé pro svoje „těžké chvosty“. Poznali byste od oka výběr z Cauchyho rozdělení od výběru z normálního rozdělení? Jak?
- (f) Porovnejte do jednoho obrázku hustoty normálního $N(0, 1)$ a Cauchyho $C(0, 1)$ rozdělení.
- (g) Nakreslete si stejným způsobem obrázek porovnávající hustotu exponenciálního rozdělení se střední hodnotou 2, gama rozdělení se střední hodnotou 2 a parametrem $p = 0.5$ a gama rozdělení se střední hodnotou 2 a parametrem $p = 2$.
(Poznámka: Zvolte vhodně rozsah bodů x , v nichž se hustoty počítají a kreslí.)

Úloha 2: Průměry ze vzrůstajícího počtu pozorování. Nyní budeme sledovat, jak se mění vlastnosti průměru v závislosti na počtu pozorování. Vzpomeňte si, co víte z přednášky o asymptotických vlastnostech \bar{X}_n .

Uvažujme gama rozdělení $\Gamma(0.5, 2)$.

- (a) Nejdříve pro představu nakreslete hustotu tohoto rozdělení.
- (b) Nagenerujte 50 výběrů z tohoto rozdělení, každý o velikosti $n = 25$ pozorování.
- Spočtete průměry ve všech těchto výběrech a vypište je. Jaká je střední hodnota $\Gamma(0.5, 2)$?
 - Spočtete odhad rozptylu průměrů. Jaký je skutečný rozptyl průměrů z 25 pozorování s rozdělením $\Gamma(0.5, 2)$? (Víte z teorie.)
 - Nakreslete histogram průměrů.
Jaké přesné rozdělení má $n \cdot \bar{X}_n$?
- (c) Zopakujte bod b) pro rozsahy výběrů $n = 250$ a $n = 2500$, případně i vyšší hodnoty, z téhož rozdělení. (Poznámka: Volte vždy stejný rozsah na ose x .)
Jak se chovají průměry při rostoucím počtu pozorování? Která věta teoreticky zdůvodňuje výsledky, které vidíte?
- (d) Vzpomeňte si na předpoklady této věty. Vyberte si rozdělení, které je nesplňuje, a ukažte, co se děje v takovém případě.

Úloha 3: Průměry ze vzrůstajícího počtu pozorování II. O chování průměru \bar{X}_n při $n \rightarrow \infty$ toho víme z teorie ještě více. Uvažujme opět např. gama rozdělení $\Gamma(0.5, 2)$.

- (a) Podobně jako v předchozí úloze nagenerujte 50 výběrů z tohoto rozdělení, o velikosti $n = 25$ a spočtete průměry v těchto výběrech. Nakreslete si histogram veličiny Z_n , kde

$$Z_n = \sqrt{n} \frac{\bar{X}_n - \mu}{\sigma},$$

kde μ a σ^2 jsou střední hodnota a rozptyl rozdělení $\Gamma(0.5, 2)$.

- (b) Zopakujte totéž pro $n = 250$, $n = 2500$. Co soudíte o asymptotickém rozdělení veličiny Z_n při $n \rightarrow \infty$? Která věta tyto závěry teoreticky zdůvodňuje?
- (c) Zamyslete se, jaké jsou předpoklady této věty, a najděte rozdělení, které je nesplňuje.

Další (nepovinné) úkoly.

- (a) Nakreslete si do jednoho obrázku hustoty exponenciálního rozdělení s parametry $\lambda = 4, 2, 1$ a $1/2$. Interpretujte, co se „děje“ s hustotou, jestliže hodnota λ klesá, resp. roste.
- (b) V úkolu 2 a 3 jsme ukazovali platnost dvou důležitých vět na gama rozdělení. Proved'te totéž pro exponenciální rozdělení s parametrem $\lambda = 5$.
- (c) Spočtete (teoreticky) medián exponenciálního rozdělení $\text{Exp}(\lambda)$. Pro hodnotu $\lambda = 4$ spočtete tuto hodnotu také pomocí \mathbb{R} a porovnejte.
- (d) Pro výběr z $\text{Exp}(\lambda)$ z úkolu 1 porovnejte teoretickou a empirickou distribuční funkci v jednom obrázku. Proved'te pro zvyšující se rozsahy výběru. Co vidíte?