

Cvičení z NSTP097
6. 12. 2010

Úvod do R, pravděpodobnostní rozdělení a limitní věty

Doporučený postup práce.

1. Na disku H si založte adresář na toto cvičení, např. NSTP097.
2. Ze stránky www.karlin.mff.cuni.cz/~omelka/Vyuka_stp097.php si stáhněte soubory `uvod.R` a `cviceni1.R` a uložte do adresáře z bodu (1).
3. Spusťte program R (najde se např. ve skupině Statistika).
4. Nastavte v programu R pracovní adresář z bodu 1. To lze udělat buď naklikáním - File/Change Dir atd. nebo pomocí příkazu `setwd("H:/NSTP097")`.
5. Pomocí File/Open script... načtěte do R soubor `uvod.R`. Příkazy z tohoto souboru lze buď kopírovat do příkazového okna, nebo lze jednoduše označit potřebný příkaz a poslat jej do příkazového okna pomocí klávesové zkratky CTRL+R.
6. Až si projdete soubor `uvod.R`, otevřete si stejným způsobem soubor `cviceni1.R`. Ten Vám napoví, jak řešit úlohy z tohoto pdf-ka.
7. V případě jakýchkoliv nejasností se nebojte obrátit na cvičícího.

Poznámka k nápovědě: Bohužel v počítačové učebně pod operačním systémem Windows nefunguje standardní nápověda, kdy do řádku napíšete přímo `?plot` nebo `help(plot)`. Jde využít html nápověda, kterou vyvoláme pomocí `help.start()`, anebo se k ní lze proklikat pomocí menu Help/... Ta však není příliš šikovná, pokud znám přesný název funkce. Jde však použít úkrok stranou. Pomocí programu `putty` se přihlásíte k serveru `artax.karlin.mff.cuni.cz`. Zde zadáte svůj login a heslo a po úspěšném přihlášení pomocí příkazu `R` spustíte R-ko. V tomto prostředí by měla nápověda `?plot` nebo `help(plot)` fungovat. Věřím, že na Vaší domácí instalaci R-ka už nebude tento úkrok stranou potřeba.

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 ,

$$f(x) = \lambda \exp\{-\lambda x\} \mathbb{I}\{x > 0\}$$

`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).
 - Spočítejte 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, mean=mu, sd=sigma)` (Pozor! σ je $\sqrt{\sigma^2}$)
D.f: `pnorm(x, mean=mu, sd=sigma)`
Náh. výběr: `rnorm(n, mean=mu, sd=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, location=a, scale=b)`
D.f: `pcauchy(x, location=a, scale=b)`
Náh. výběr: `rcauchy(n, location=a, scale=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.)

Normálního rozdělení

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}, \quad EX = \mu, \quad \text{Var } X = \sigma^2.$$

Cauchyho rozdělení

$$f(x) = \frac{1}{\pi(1+x^2)}, \quad EX \text{ neexistuje.}$$

Gamma rozdělení $\Gamma(a, p)$

$$f(x) = \frac{a^p}{\Gamma(p)} x^{p-1} \exp\{-ax\} \mathbb{I}\{x > 0\}, \quad EX = \frac{p}{a}, \quad \text{Var } X = \frac{p}{a^2}.$$

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.
- Spočítejte průměry ve všech těchto výběrech a vypište je. Jaká je střední hodnota $\Gamma(0.5, 2)$?
 - Spočítejte 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 nagenertejte 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. Proveďte 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 R a porovnejte.
- (d) Pro výběr z $\text{Exp}(\lambda)$ z úkolu 1 porovnejte teoretickou a empirickou distribuční funkci v jednom obrázku. Proveďte pro zvyšující se rozsahy výběru. Co vidíte?