

# Matematika III – 11. týden

## Momentové funkce, centrální limitní věta, příklady důležitých rozdělení

Jan Slovák

Masarykova univerzita  
Fakulta informatiky

30.11.-4. 12. 2015

# Obsah přednášky

- 1 Literatura
- 2 Momentová funkce (připomenutí)
- 3 Centrální limitní věta
- 4 Co potkáme ve statistice

# Plán přednášky

- 1 Literatura
- 2 Momentová funkce (připomenutí)
- 3 Centrální limitní věta
- 4 Co potkáme ve statistice

## Kde je dobré číst?

- Karel Zvára, Josef Štěpán, Pravděpodobnost a matematická pravděpodobnost statistika, Matfyzpress, 2006, 230pp.
- J. Slovák, M. Panák, M. Bulant, Matematika drsně a svižně, Muni Press, Brno 2013, v+773 s., elektronická edice [www.math.muni.cz/Matematika\\_drsne\\_svizne](http://www.math.muni.cz/Matematika_drsne_svizne)
- Marie Budíková, Štěpán Mikoláš, Pavel Osecký, Teorie pravděpodobnosti a matematická statistika (sbírka příkladů), Masarykova univerzita, 3. vydání, 2004, 117 stran, ISBN 80-210-3313-4.
- Marie Budíková, Tomáš Lerch, Štěpán Mikoláš, Základní statistické metody, Masarykova univerzita, 2005, 170 stran, ISBN 80-210-3886-1.
- Riley, K.F., Hobson, M.P., Bence, S.J. Mathematical Methods for Physics and Engineering, second edition, Cambridge University Press, Cambridge 2004, ISBN 0 521 89067 5, xxiii + 1232 pp.

# Plán přednášky

- 1 Literatura
- 2 Momentová funkce (připomenutí)
- 3 Centrální limitní věta
- 4 Co potkáme ve statistice

# Momenty

Podobně jako rozptyl můžeme uvažovat výrazy vyšších řádů:

$$\mu'_k = EX^k, \quad \mu_k = E(X - EX)^k.$$

Nazýváme je  $k$ -tý moment a  $k$ -tý centrální moment náhodné veličiny  $X$ . Momenty lze všechny dostat jako koeficienty v mocninné řadě následujícím způsobem.

# Momenty

Podobně jako rozptyl můžeme uvažovat výrazy vyšších řádů:

$$\mu'_k = E X^k, \quad \mu_k = E(X - E X)^k.$$

Nazýváme je  $k$ -tý moment a  $k$ -tý centrální moment náhodné veličiny  $X$ . Momenty lze všechny dostat jako koeficienty v mocninné řadě následujícím způsobem.

Pro volný reálný parametr  $t$  definujeme **momentovou vytvořující funkci** pro náhodnou veličinu  $X$  vztahem

$$M_X(t) = E e^{tX}.$$

Tato funkce (za docela rozumných předpokladů následující věty) zcela určuje náhodné veličiny a má řadu užitečných vlastností (tj. *stejná momentová funkce na nějakém netriviálním intervalu  $\implies$  stejná distribuční funkce*).

## Theorem

*Nechť  $X$  je náhodná veličina pro kterou na intervalu  $(-a, a)$  existuje její analytická momentová vytvořující funkce. Pak na tomto intervalu je  $M_X(t)$  dána absolutně konvergující řadou*

$$M_t(X) = \sum_{k=0}^{\infty} \frac{t^k}{k!} E X^k.$$

## Theorem

*Pro součet náhodných veličin platí:*

$$M_{X+Y}(t) = M_X(t)M_Y(t).$$



# Momentová vytvořující funkce pro $X \sim \text{Bi}(0, 1)$

Často je jednodušší počítat momenty z jejich vytvořující funkce než přímo.

# Momentová vytvořující funkce pro $X \sim \text{Bi}(0, 1)$

Často je jednodušší počítat momenty z jejich vytvořující funkce než přímo.

Pro alternativní rozdělení náhodné veličiny  $Y \sim A(p)$  spočteme snadno

$$M_Y(t) = E e^{tY} = e^0(1 - p) + e^t p = p(e^t - 1) + 1.$$

# Momentová vytvořující funkce pro $X \sim \text{Bi}(0, 1)$

Často je jednodušší počítat momenty z jejich vytvořující funkce než přímo.

Pro alternativní rozdělení náhodné veličiny  $Y \sim A(p)$  spočteme snadno

$$M_Y(t) = E e^{tY} = e^0(1 - p) + e^t p = p(e^t - 1) + 1.$$

Protože je binomické rozdělení  $X \sim \text{Bi}(n, p)$  dáno jako součet  $n$  alternativních rozdělení  $Y_i \sim A(p)$ , je zjevně v tomto případě

$$M(t) = M_X(t) = (p(e^t - 1) + 1)^n.$$

# Momentová vytvořující funkce pro $X \sim \text{Bi}(0, 1)$

Často je jednodušší počítat momenty z jejich vytvořující funkce než přímo.

Pro alternativní rozdělení náhodné veličiny  $Y \sim A(p)$  spočteme snadno

$$M_Y(t) = E e^{tY} = e^0(1 - p) + e^t p = p(e^t - 1) + 1.$$

Protože je binomické rozdělení  $X \sim \text{Bi}(n, p)$  dáno jako součet  $n$  alternativních rozdělení  $Y_i \sim A(p)$ , je zjevně v tomto případě

$$M(t) = M_X(t) = (p(e^t - 1) + 1)^n.$$

Obecně platí  $\mu'_k = \frac{d^k}{dt^k} M_X(t)|_{t=0}$ . Je tedy např. první moment binomického rozdělení skutečně  $np$  (první derivace  $M(t)$  v nule), což je střední hodnota. Druhý moment je  $np(1 - p)$ , čímž jsme ověřili výsledek pro rozptyl.

Momentová vytvořující funkce pro  $Z \sim N(0, 1)$ 

$$\begin{aligned}M_Z(t) &= \int_{-\infty}^{\infty} e^{tx} \frac{1}{\sqrt{2\pi}} \exp(-x^2/2) dx \\&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2 - 2tx + t^2 - t^2}{2}\right) dx \\&= \exp(t^2/2) \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x-t)^2}{2}\right) dx \\&= \exp(t^2/2).\end{aligned}$$

(V předposledním řádku je integrálem dána pravděpodobnost jakékoliv hodnoty pro normální rozdělení, proto je to jednička.)

# Momentová vytvořující funkce pro $Z \sim N(0, 1)$

$$\begin{aligned}
 M_Z(t) &= \int_{-\infty}^{\infty} e^{tx} \frac{1}{\sqrt{2\pi}} \exp(-x^2/2) dx \\
 &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2 - 2tx + t^2 - t^2}{2}\right) dx \\
 &= \exp(t^2/2) \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x-t)^2}{2}\right) dx \\
 &= \exp(t^2/2).
 \end{aligned}$$

(V předposledním řádku je integrálem dána pravděpodobnost jakékoliv hodnoty pro normální rozdělení, proto je to jednička.)

Derivováním:  $(M_Z)'(0) = 0$  a  $(M_Z)''(0) = (te^{t^2/2})'(0) = 1$ . Je tedy skutečně

$$E Z = 0, \quad \text{var } Z = 1.$$

# Plán přednášky

- 1 Literatura
- 2 Momentová funkce (připomenutí)
- 3 Centrální limitní věta**
- 4 Co potkáme ve statistice

Uvažme nezávislé náhodné veličiny  $Y_1, Y_2, \dots$ , které mají všechny stejné rozdělení se střední hodnotou 0 a rozptylem 1.

Předpokládejme, že třetí absolutní moment  $E|Y_i|^3$  je konečný.

Pro náhodnou veličinu  $S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n Y_i$  spočtěme momentovou funkci (koeficient  $n^{-1/2}$  je volen tak, aby rozptyl  $S_n$  byl stále 1)

$$M_{S_n} = \prod_{i=1}^n E e^{(t/\sqrt{n})Y_i} = (M_Y(t/\sqrt{n}))^n,$$

kde  $M_Y$  je společná momentová funkce všech veličin  $Y_i$ .



Uvažme nezávislé náhodné veličiny  $Y_1, Y_2, \dots$ , které mají všechny stejné rozdělení se střední hodnotou 0 a rozptylem 1.

Předpokládejme, že třetí absolutní moment  $E|Y_i|^3$  je konečný.

Pro náhodnou veličinu  $S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n Y_i$  spočtěme momentovou funkci (koeficient  $n^{-1/2}$  je volen tak, aby rozptyl  $S_n$  byl stále 1)

$$M_{S_n} = \prod_{i=1}^n E e^{(t/\sqrt{n})Y_i} = (M_Y(t/\sqrt{n}))^n,$$

kde  $M_Y$  je společná momentová funkce všech veličin  $Y_i$ . Nyní

$$M_Y(t/\sqrt{n}) = 1 + 0 \frac{t}{\sqrt{n}} + 1 \frac{t^2}{2n} + o(t^2/n)$$

a v limitě proto dostáváme

$$\lim_{n \rightarrow \infty} M_{S_n}(t) = \lim_{n \rightarrow \infty} \left( 1 + \frac{t^2}{2n} + o(1/n) \right)^n = e^{t^2/2}.$$

**To je právě momentová funkce pro rozdělení  $N(0, 1)$ !**

Tím jsme skoro dokázali:

### Theorem (Centrální limitní věta)

*Nechť  $Y_1, Y_2, \dots$  jsou nezávislé náhodné veličiny se společnou střední hodnotou  $E Y_i = \mu$ , rozptylem  $\text{var } Y_i = \sigma^2 > 0$  a konečným třetím absolutním momentem  $E|Y_i|^3$ . Pro distribuční funkce náhodných veličin*

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{1}{\sigma} (Y_i - \mu)$$

*platí*

$$\lim_{n \rightarrow \infty} P(S_n < x) = \Phi(x),$$

*kde  $\Phi(x)$  je distribuční funkce normálního rozdělení  $N(0, 1)$ .*

Všimněme si: součty  $X_n = \sum_{i=1}^n Y_i$  mají střední hodnotu  $n\mu$  a rozptyl  $n\sigma^2$ . Veličiny  $S_n$  jsou tedy právě normované veličiny  $X_n$ .

Pokud jsou  $Y_i \sim A(p)$  nezávislé, pak  $E(Y_i)^3 = p < \infty$  a všechny podmínky centrální limitní věty jsou splněny,  $\mu = p$ ,  $\sigma^2 = p(1 - p)$ .

Pokud jsou  $Y_i \sim A(p)$  nezávislé, pak  $E(Y_i)^3 = p < \infty$  a všechny podmínky centrální limitní věty jsou splněny,  $\mu = p$ ,  $\sigma^2 = p(1 - p)$ . Součtové veličiny  $X_n = \sum_{i=1}^n Y_i$  pak představují právě binomická rozdělení  $\text{Bi}(n, p)$  a příslušné normované veličiny jsou

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left( \frac{Y_i - p}{\sqrt{p(1-p)}} \right) = \frac{X_n - np}{\sqrt{np(1-p)}}.$$

Podle centrální limitní věty má tato veličina pro velká  $n$  rozdělení velmi podobné rozdělení  $N(0, 1)$ .

Pokud jsou  $Y_i \sim A(p)$  nezávislé, pak  $E(Y_i)^3 = p < \infty$  a všechny podmínky centrální limitní věty jsou splněny,  $\mu = p$ ,  $\sigma^2 = p(1 - p)$ . Součtové veličiny  $X_n = \sum_{i=1}^n Y_i$  pak představují právě binomická rozdělení  $\text{Bi}(n, p)$  a příslušné normované veličiny jsou



$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left( \frac{Y_i - p}{\sqrt{p(1 - p)}} \right) = \frac{X_n - np}{\sqrt{np(1 - p)}}.$$

Podle centrální limitní věty má tato veličina pro velká  $n$  rozdělení velmi podobné rozdělení  $N(0, 1)$ .

Jinými slovy, rozdělení  $\text{Bi}(n, p)$  je velice blízké rozdělení  $N(np, np(1 - p))$  pro velká  $n$ . To je obsahem tzv.

Laplaceovy–Moivreovy věty. To jsme už viděli minule na obrázcích:

Pro hodnoty  $Bi(5000, 0.5)$  je výsledek vidět na obrázku níže. Druhá křivka na obrázku je grafem funkce  $f(x) = e^{-x^2/2}$ .



Aproximace binomického rozdělení normálním se často považuje v praxi za dostatečnou, jestliže  $np(1 - p) > 9$

Při praktických průzkumech zpravidla věříme „zákonu velkých čísel“. Potřebujeme přitom rozhodnout, jak velký vzorek už postačuje.

Typickým příkladem je např. tato úloha: Chceme zjistit poměr  $p$  osob s danou krevní skupinou  $A$  v populaci. U kolika osob je třeba krevní skupinu skutečně zjistit, abychom měli 90% pravděpodobnost, že naše zjištění se nebude lišit o více než 5%.

Při praktických průzkumech zpravidla věříme „zákonu velkých čísel“. Potřebujeme přitom rozhodnout, jak velký vzorek už postačuje.

Typickým příkladem je např. tato úloha: Chceme zjistit poměr  $p$  osob s danou krevní skupinou  $A$  v populaci. U kolika osob je třeba krevní skupinu skutečně zjistit, abychom měli 90% pravděpodobnost, že naše zjištění se nebude lišit o více než 5%. Propočítáním zjistíme, že (nezávisle na  $p$ ) vždy stačí odhadnout  $p = X/n$ , kde  $X$  je náhodná veličina udávající počet osob majících požadovanou skupinu, pro vzorek 270 lidí.



# Plán přednášky

- 1 Literatura
- 2 Momentová funkce (připomenutí)
- 3 Centrální limitní věta
- 4 Co potkáme ve statistice**

Rozdělení  $\chi^2$ 

Ve statistice budeme pracovat s charakteristikami náhodných vektorů, které budou obdobné výběrovému průměru a rozptylu, ale také s relativními poměry takových charakteristik atd. Podíváme se teď na několik takových případů.

Uvažme  $Z \sim N(0, 1)$  a spočtěme hustotu  $f_Y(x)$  pro  $Y = Z^2$ . Evidentě je  $f_Y(x) = 0$  pro  $x \leq 0$ , pro kladná  $x$

$$\begin{aligned} F_Y(x) &= P(Y < x) = P(-\sqrt{x} < Z < \sqrt{x}) \\ &= \int_{-\sqrt{x}}^{\sqrt{x}} \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz = \int_0^x \frac{1}{\sqrt{2\pi}} t^{-1/2} e^{-t/2} dt. \end{aligned}$$

Hustotu dostaneme derivací

$$f_Y(x) = \frac{d}{dx} F_Y(x) = \frac{1}{\sqrt{2\pi}} x^{-1/2} e^{-x/2}.$$

Tomuto rozdělení se říká  $\chi^2$  s **jedním stupněm volnosti**, píšeme  $Y \sim \chi^2$ .

# Gama rozdělení $Y \sim \Gamma(a, b)$

Výběrový rozptyl bude odpovídat součtům takovýchto nezávislých veličin.

Uvažme hustotu (trochu obecnějšího tvaru než u  $\chi^2$ )

$$f_X(x) = cx^{a-1} e^{-bx}$$

pro  $x > 0$ , zatímco  $f_X(x) = 0$  pro nekladná  $x$  ( $\chi^2$  odpovídá volbě  $a = b = 1/2$ ).

Je třeba volit  $c = \frac{b^a}{\Gamma(a)}$  a jde o rozdělení  $\Gamma(a, b)$ .

$k$ -tý moment takové veličiny  $X$  je

$$\begin{aligned} E X^k &= \int_0^{\infty} x^k \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} dx \\ &= \frac{\Gamma(a+k)}{\Gamma(a)b^r} \int_0^{\infty} \frac{b^{a+k}}{\Gamma(a+k)} x^{a-1+k} e^{-bx} dx \\ &= \frac{\Gamma(a+k)}{\Gamma(a)b^k} \end{aligned}$$

(protože integrál z hustoty rozdělení  $\Gamma(a+k, b)$  v posledním upravovaném výrazu je nutně roven jedné)

Zejména tedy vidíme, že  $E X = \frac{\Gamma(a+1)}{b\Gamma(a)} = \frac{a}{b}$ , zatímco

$$\text{var } X = E X^2 - (E X)^2 = \frac{\Gamma(a+2)}{b^2\Gamma(a)} - \frac{a^2}{b^2} = \frac{(a+1)a - a^2}{b^2} = \frac{a}{b^2}.$$

Momentová vytvořující funkci pro všechny hodnoty  $-b < t < b$  je

$$\begin{aligned} M_X(t) &= \int_0^{\infty} e^{tx} \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} dx \\ &= \frac{b^a}{(b-t)^a} \int_0^{\infty} \frac{(b-t)^a}{\Gamma(a)} x^{a-1} e^{-(b-t)x} dx \\ &= \frac{b^a}{(b-t)^a}. \end{aligned}$$

Pro součet nezávislých rozdělení  $Y = X_1 + \dots + X_n$  s rozděleními  $X_i \sim \Gamma(a_i, b)$  tedy okamžitě dostáváme momentovou vytvořující funkci (pro hodnoty  $|t| < b$ )

$$M_Y(t) = \left( \frac{b}{b-t} \right)^{a_1 + \dots + a_n},$$

tj.  $Y \sim \Gamma(a_1 + \dots + a_n, b)$ . (Velmi podstatný je přitom předpoklad, že všechna gamma rozdělení sdílí stejnou hodnotu  $b$ ).

rozdělení  $\chi^2$ 

Jako okamžitý důsledek nyní dostáváme hustotu rozdělení veličiny  $Y = Z_1^2 + \dots + Z_n^2$ , kde všechna  $Z_i \sim N(0, 1)$ . Jde totiž o gamma rozdělení  $Y \sim \Gamma(n/2, 1/2)$  a má hustotu

$$f_Y(x) = \frac{1}{2^{n/2}\Gamma(n/2)} x^{n/2-1} e^{-x/2}.$$

Tomuto speciálnímu případu gamma rozdělení říkáme rozdělení  $\chi^2$  s  $n$  stupni volnosti. Značíme jej zpravidla  $Y \sim \chi_n^2$ .

# F-rozdělení

Při prorovnání výběrových rozptylů potkáme veličiny, které jsou dány podílem

$$U = \frac{X/k}{Y/m}$$

$X \sim \chi_k^2$  a  $Y \sim \chi_m^2$ .

Náhodná veličina  $U = \frac{X/k}{Y/m}$  má hustotu  $f_U(u)$

$$f_U(u) = \frac{\Gamma((k+m)/2)}{\Gamma(k/2)\Gamma(m/2)} \left(\frac{k}{m}\right)^{k/2} u^{k/2-1} \left(1 + \frac{k}{m}u\right)^{-(k+m)/2}.$$

Takovému rozdělení se říká **Fisherovo-Snedecorovo rozdělení s  $k$  a  $m$  stupni volnosti**, zkráceně také **F-rozdělení**.

# t-rozdělení

Další potřebné rozdělení se objevuje při zkoumání podílu veličin  $Z \sim N(0, 1)$  a  $\sqrt{X/n}$ , kde  $X \sim \chi_n^2$  (tj. zajímá nás poměr  $Z$  a směrodatné odchyly nějakého výběru).

Dostaneme náhodnou veličinu

$$T = \frac{Z}{\sqrt{X/n}}$$

a hustotou  $f_T(t)$

$$f_T(t) = \frac{\Gamma((n+1)/2)}{\Gamma(n/2)\sqrt{n\pi}} \left(1 + \frac{t^2}{n}\right)^{-(n+1)/2}.$$

Tomuto rozdělení říkáme **Studentovo t-rozdělení s  $n$  stupni volnosti**.