

Cvičení ze statistiky - 6

Filip Děchtěrenko

Minule bylo..

- Probrali jsme základní charakteristiky pravděpodobnostních modelů a diskrétní modely
- Tyhle termíny by měly být známé:
 - Distribuční funkce
 - Střední hodnota
 - Rozptyl
 - Z rozdělení
 - Hypergeometrické rozdělení
 - Alternativní rozdělení
 - Binomické rozdělení
 - Kombinační číslo

Příklady na rozdělení

1. Lovec má 5 patron, střílí dokud netrefí (nebo nedojdou) a p st zásahu je 0.4. Popište rozdělení, střední hodnotu a rozptyl
2. Pravděpodobnost, že se narodí kluk, je 0,515. Kolik potřebujeme dětí, aby p st, že je v nich aspoň jeden kluk, je větší než 99%?
3. V urně je 5 černých a 3 zelené koule. Náhodně vyberu 2 koule, jaká je pravděpodobnost, že právě jedna bude zelená?
4. To samé jako 3, ale kouli tam po vytažení vrátím?
5. To samé jako 3, ale v urně je 5000 černých a 3000 zelených

Spojité rozdělení

- Zatím jsme měli pouze diskrétní proměnné (tedy v oboru hodnot jsou mezery)
- Zajímá nás případ, kdy je oborem hodnot interval
- Nemůžeme mít vyjádřenou pst pro jednotlivé hodnoty z oboru hodnot (je jich nekonečno)-> zavedeme *hustotu* – spojitá funkce pro jednotlivé hodnoty z intervalu $f(x)$

Spojité rozdělení - F(x)


- Distribuční funkce je taky spojitá!
- Vztah mezi hustotou a distribuční funkcí

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(t) dt$$

- Pro rozsahy používáme
 $P(a < X \leq b) = F(b) - F(a)$

- Distribuční funkci
budeme používat při výpočtech

Spojité rozdělení



Spojité rozdělení – EX a $\text{Var } X$


- Střední hodnota i rozptyl mají stejný význam, jen se počítají jinak
- $EX = \int_{-\infty}^{\infty} xf(x)dx$
- $\text{Var } X = \int_{-\infty}^{\infty} (x - EX)^2 f(x)dx$
- Naštěstí to už za nás pro vybrané rozdělení spočítal 😊

Rovnoměrné rozdělení


- Každé číslo z intervalu a, b je stejně pravděpodobné
- $X=(a, b)$
- Parametry
 - a : dolní rozsah intervalu
 - b : horní rozsah intervalu
- $f(x) = \frac{1}{b-a}$ pro $a < x < b$ (hustota)
- $F(x) = \frac{x-a}{b-a}$ pro $a < x < b$ (distribuční funkce)
- $EX = \frac{b+a}{2}$
- $\text{Var } X = \frac{(b-a)^2}{12}$
- Značí se $X \sim \text{Ro}(a, b)$

Rovnoměrné rozdělení - grafy

- Hustota
 - Každá z hodnot je stejně pravděpodobná




- Distribuční funkce





Normální (Gaussovo) rozdělení

- Velmi důležité rozdělení – působí-li hodně faktorů zároveň, má veličina náhodné rozdělení
- $X = (-\infty, \infty)$
- Parametry:
 - μ : střední hodnota
 - σ^2 : rozptyl
- $$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$
- $F(x)$ nemůže být vyjádřena funkcí (jedině numericky)
- $EX = \mu$
 $\text{Var } X = \sigma$
- Značí se $X \sim N(\mu, \sigma^2)$



Normální rozdělení -


- Hustota
- Distribuční funkce
 - Analyticky sice nelze vyjádřit, ale graf můžeme zobrazit



Šikmost a špičatost

- Pro popis rozdělení se používá kromě střední hodnoty a průměru ještě šikmost a špičatost
- Koeficient šikmosti vypovídá o symetrii rozdělení

$$\gamma_1 = \frac{E(X - EX)^3}{(\text{var } X)^{3/2}}$$




Negative Skew

Positive Skew

- Koeficient špičatosti vypovídá o velikosti „ramen“

$$\gamma_2 = \frac{E(X - EX)^4}{(\text{var } X)^2} - 3$$

- Existují i výběrové varianty těchto koeficientů



N(0,1) rozdělení

- Náhodnou veličinu značíme Z
- Jedná se o normální rozdělení s parametry $\mu=0, \sigma^2=1$
- Máme tabulku pro hodnoty distribuční funkce tohoto rozdělení
- Převádí se na něj všechna normální rozdělení (a hodnoty se poté najdou v tabulkách pro N(0,1) rozdělení)
- Značíme $P(Z \leq z) = \Phi(z)$

Tabulky $N(0,1)$ – směr $z \rightarrow p$

- Počítáme p-hodnoty pro zadané z-hodnoty
- Máme jen pro z-hodnoty 0-4
 - Platí $P(Z > 4) = 1$ (proto nepotřebujeme vyšší rozsah)
 - Platí $\Phi(z) = 1 - \Phi(-z)$ (proto nepotřebujeme tabulky pro záporné hodnoty)
 - Příklad: $z = -0.5$
 - $\Phi(-0.5) = 1 - \Phi(0.5) = 1 - 0.6915 = 0.3085$
- Ukázka tabulky:

z	$\Phi(z)$
0.0	0.500
0.02	0.508
0.04	0.516
0.06	0.5239

Tabulky $N(0,1)$ – směr $p \rightarrow z$

- Počítáme p -hodnoty pro zadané z -hodnoty
- Pro p -hodnotu mezi 0.5 a 1 najdeme v tabulce (ale díváme se do druhého sloupce)
- Pro p -hodnotu mezi 0 a 0.5: najdeme v tabulce hodnotu pro „ $1-p$ “ a k výsledné z -hodnotě přidáme mínus
 - Příklad: $0.4 = P(Z \leq z)$
V tabulce najdeme z -hodnotu pro $p=0.6$
→ 0.25 a přidáme mínus
 $z = -0.25$

Mccalova transformace

- Mccalova transformace je jedna z metod, které se používá k transformaci rozdělení s vysokou šikmostí na normální rozdělení
- Pokud transformujeme z binomického rozdělení, používáme i korekci na spojitost
- Hodím 5 krát mincí, můj hrubý skór bude součet orlů. Toto budu opakovat 1000 krát.

HS	četnost	Rel. četnost	Kum. rel. četnost	Korekce na spoj.	Z-skór	T-skór
0	150	0,15	0,15	0,075	-1,44	36
1	400	0,4	0,55	0,35	-0,385	46
2	200	0,2	0,75	0,65	0,3853	54
3	120	0,12	0,87	0,81	0,8779	59
4	80	0,08	0,95	0,91	1,3408	63
5	50	0,05	1	0,975	1,96	70

Mccallova transformace-výpočet

- Vycházíme ze sloupců HS a četnost
- Označíme si:
 - Četnost – Č
 - Relativní četnost – RČ
 - Kumulovaná relativní četnost – KRČ
 - Korekce na spojitost – KS
 - Z-skór- Z
 - T-skór-T
- Pokud budeme mluvit o i-tém řádku, označíme příslušné políčko dolním indexem i
- Platí
 - $RČ_i = \frac{č_i}{n}$
 - $KRČ_i = KRČ_{i-1} + RČ_i$
 $KRČ_1 = RČ_1$
 - $KS_i = KRČ_{i-1} + 0.5RČ_i$
 $KS_1 = 0.5RČ_1$
 - Z – spočítáme přes inverzní hledání v tabulce
 - $T_i = Z_i \cdot 10 + 50$ a zaokrouhlíme
 - Pokud je $KS_i=1$, nepočítáme Z_i a za T_i dosadíme maximální hodnotu (tedy 100)
 - Pokud je $KS_i=0$, nepočítáme Z_i a za T_i dosadíme minimální hodnotu (tedy 0)

Důležitá vlastnost $N(\mu, \sigma^2)$

- Má-li náhodná veličina $X \sim N(\mu, \sigma^2)$ a $Y = aX + b$, potom $Y \sim N(a + b\mu, b^2\sigma^2)$, kde $b \neq 0$
 - Máme tedy předpis, jak na sebe rozdělení převádět
 - Konkrétně pokud $X \sim N(\mu, \sigma^2)$, potom $Z = \frac{X - \mu}{\sigma}$ má rozdělení $N(0, 1)$
 - Vyskytne-li se nám někde výraz $P\left(\frac{X - \mu}{\sigma} \leq z\right)$, přepíšeme si to na $P\left(\frac{X - \mu}{\sigma} \leq z\right) = P(Z \leq z) = \Phi(z)$ a najdeme v tabulkách

Příklad (výpočet psti)

- Počet bodů v testu má normální rozdělení $N(50, 144)$
 - Jaká je pravděpodobnost, že náhodně vybraný člověk má více než 74 bodů?
- Řešení:
 - $X \sim N(50, 12^2)$ značí počet bodů v testu
 $P(X > 70)$ je pst, že náhodně vybraný člověk má více než 70 bodů
 - $P(X > 70) = 1 - P(X \leq 70) = 1 - P\left(\frac{X - 50}{12} \leq \frac{74 - 50}{12}\right) = 1 - P(Z \leq 2) = 1 - \Phi(2) = 1 - 0.9772 = 0.0228$

Příklad

- Počet bodů v testu má normální rozdělení $N(50,144)$
 - Jaká je pravděpodobnost, že náhodně vybraný člověk má mezi 30 a 45 body?
- Řešení:
 - $X \sim N(50, 12^2)$ značí počet bodů v testu
 $P(30 < X < 45)$ je pst, že náhodně vybraný člověk má mezi 30 a 45 body
 - $$P(30 \leq X \leq 45) = P\left(\frac{30-50}{12} \leq \frac{X-50}{12} \leq \frac{45-50}{12}\right) =$$
$$= P(-1.66 \leq Z \leq -0.42) = P(-0.42) - P(-1.66) =$$
$$= (1 - \Phi(0.42)) - (1 - \Phi(1.66)) = \Phi(1.66) - \Phi(0.42) = 0.9515 - 0.6554 =$$
$$= 0.30$$

Příklad (výpočet z-hodnoty)

- Výška člověka pochází z normálního rozdělení $N(160, 324)$. Jak je vysoký člověk, který je větší než 70% populace?
- Řešení:
 - $X \sim N(160, 18^2)$ značí počet bodů v testu
 - $0.7 = P(X \leq v) = P\left(\frac{X-160}{18} \leq \frac{v-160}{18}\right) = P\left(Z \leq \frac{v-160}{18}\right)$
 - $0.7 = P\left(Z \leq \frac{v-160}{18}\right)$ (a hledáme v tabulkách podle postupu p->z)
 - $\frac{v-160}{18} = 0.52$
 - $v = 0.52 * 18 + 160$
 - $v = 169.36$

Problémy při inverzním výpočtu

- Pozor, pokud budeme mít rovnici v jiném tvaru, než $p=P(X\leq v)$, nemůžeme hledat v tabulkách.
- Příklad: $0.4=1-P(X\leq v)$ – nemůžeme hledat (nevíme, pro jakou hodnotu). Upravíme si rovnici do tvaru $0.6=P(X\leq v)$, a až poté budeme hledat v tabulkách

Přehled fint

- $P(Z > z) = 1 - P(Z \leq z) = 1 - \Phi(z)$
 $P(Z \geq z) = 1 - P(Z < z) = 1 - \Phi(z)$
Aspoň na jedné straně musí být rovnost
- $P(X < a \text{ nebo } X > b) = 1 - P(a \leq X \leq b)$
dá se to představit na číselné ose
- $\Phi(-a) = 1 - \Phi(a)$
toto použijeme vždy, když budeme chtít najít zápornou hodnotu v tabulce
- $P(a < Z \leq b) = P(Z \leq b) - P(Z \leq a) = \Phi(b) - \Phi(a)$
obvykle bývá a záporné, potom
 $P(-a < Z \leq b) = \Phi(b) - \Phi(-a) = \Phi(b) - (1 - \Phi(a)) = \Phi(b) + \Phi(a) - 1$
- $P(-a < Z \leq a) = 2\Phi(a) - 1$