

KGG/STG Statistika pro geografy

4. Teoretická rozdělení

Mgr. David Fiedor
9. března 2015

Osnova

- 1 Úvod
- 2 Normální rozdělení $N(\mu, \sigma^2)$
- 3 Teoretická rozdělení diskrétního typu
- 4 Rozdělení využívaná v testování hypotéz
- 5 Další v geografii využívaná rozdělení

Vybraná rozdělení náhodných proměnných

- normální rozdělení
- normované normální rozdělení
- binomické rozdělení
- Poissonovo rozdělení
- χ^2 rozdělení
- Studentovo t rozdělení
- Fisher-Snedecorovo rozdělení
- exponenciální, lognormální,...

Základní charakteristiky


- Gaussovo rozdělení
- nejčastěji používané rozdělení spojitě náhodné proměnné
- některé jiné proměnné lze převést (transformovat) na proměnnou, která má normální rozdělení
- existuje mnoho statistických procedur odvozených pro toto rozdělení
- u rozdělení s větším rozsahem lze rozdělení výběrových průměrů aproximovat normálním rozdělením
- zvonovitý tvar křivky

Frekvenční funkce normálního rozdělení

- frekvenční funkce $f(x) =$ hustota pravděpodobnosti


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/2\sigma^2}$$

- parametr μ určuje, kde má křivka maximum, zároveň je tato hodnota mediánem a modem
- parametr σ určuje, jak jsou po obou stranách od hodnoty μ „vzdáleny“ inflexní body (jak je křivka roztažena do šířky)







Distribuční funkce normálního rozdělení

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-(x-\mu)^2/2\sigma^2} dx$$




Normální rozdělení



Pravidlo „šesti sigma“

Plocha vymezená úsečkami		je rovna	v % plochy
$\bar{x} - \sigma$	$\bar{x} + \sigma$	0,683	68,3
$\bar{x} - 1,96\sigma$	$\bar{x} + 1,96\sigma$	0,950	95,0
$\bar{x} - 2,58\sigma$	$\bar{x} + 2,58\sigma$	0,990	99,0
$\bar{x} - 3\sigma$	$\bar{x} + 3\sigma$	0,997	99,7

Normální rozdělení



Normované normální rozdělení $N(0, 1)$

- hodnoty μ a σ se výběr od výběru liší
- frekvenční funkce má různý tvar



$$z = \frac{x - \mu}{\sigma}$$

- normované normální rozdělení nezáleží na parametrech μ a σ


- frekvenční funkce $f(z) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$

- distribuční funkce $F(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-x^2/2} dz$

Normované normální rozdělení $N(0, 1)$



Normované normální rozdělení



Obr. 3.9 Normování normálního rozdělení

Extremita jevů

Pravděpodobná chyba c pro normální rozdělení
 $c = 0,6745s$

slovní označení extremity	symbol	meze	pravděpodobnost výskytu jevu (%)	meze	pravděpodobnost výskytu jevu (%)
extrémně podnormální	EP	$< x - 3s$	0,135	$< x - 3c$	2,150
silně podnormální	SP	$x - 3s$ až $x - 2s$	2,190	$x - 3c$ až $x - 2c$	8,870
podnormální	P	$x - 2s$ až $x - s$	13,590	$x - 2c$ až $x - c$	13,980
normální	O	$x - s$ až $x + s$	68,270	$x - c$ až $x + c$	50,000
nadnormální	N	$x + s$ až $x + 2s$	13,590	$x + c$ až $x + 2c$	13,980
silně nadnormální	SN	$x + 2s$ až $x + 3s$	2,190	$x + 2c$ až $x + 3c$	8,870
extrémně nadnormální	EN	$> x + 3s$	0,135	$> x + 3c$	2,150

Příklad - zadání

Plochu obhospodařované zemědělské půdy u sledovaného souboru farmářů modelujeme normálním rozdělením. Zjistili jsme, že parametry rozdělení $N(3\,400\text{ m}^2, 360\,000\text{ m}^2)$. Vypočtete pravděpodobnost, že náhodně vybraný zemědělec bude mít:

- a) méně než $4\,000\text{ m}^2$ půdy
- b) více než $4\,200\text{ m}^2$ půdy
- c) méně než $3\,000\text{ m}^2$ půdy
- d) mezi $2\,800\text{ m}^2$ a $4\,000\text{ m}^2$ půdy

Příklad - řešení

Lze řešit několika způsoby:


- převodem na normované normální rozdělení a využití statistických tabulek
- pomocí programu STATISTICA modelujícího hodnoty frekvenční a distribuční funkce - pravděpodobnostní kalkulátor
- pomocí funkce zadané do dlouhého jména proměnné v programu STATISTICA

Příklad - řešení a)

Transformace hodnoty x na normovanou veličinu:

$$z = \frac{x - \mu}{\sigma} = \frac{4\,000 - 3\,400}{600} = 1$$

Můžeme tedy psát: $P(x \leq 4\,000) = P(z \leq 1) = 0,84134$




Příklad - řešení b)

Transformace hodnoty x na normovanou veličinu:

$$z = \frac{x - \mu}{\sigma} = \frac{4\,200 - 3\,400}{600} = 1,33$$

Pravděpodobnost, že normovaná proměnná překročí hodnotu 1,33 ovšem v tabulkách není. Proto:

$$P(x \geq 4\,200) = P(z \geq 1,33) = 1 - P(z \leq 1,33) = 1 - 0,90824 = 0,09176$$




Příklad - řešení c)

Transformace hodnoty x na normovanou veličinu:

$$z = \frac{x - \mu}{\sigma} = \frac{3000 - 3400}{600} = -0,67$$

Pravděpodobnost $P(z \leq -0,67)$ určíme na základě symetrie normovaného normálního rozdělení. Můžeme tedy psát:

$$P(z \leq -0,67) = P(z \geq 0,67) = 1 - P(z \leq 0,67) = 1 - 0,74857 = 0,25143$$



Příklad - řešení d)

Transformace hodnoty x na normovanou veličinu:

$$z_1 = \frac{x - \mu}{\sigma} = \frac{2\,800 - 3\,400}{600} = -1$$

$$z_2 = \frac{x - \mu}{\sigma} = \frac{4\,000 - 3\,400}{600} = 1$$


Pravděpodobnost mezi hodnotami 2 800 a 4 000 m² u rozdělení $N(3\,400 \text{ m}^2, 360\,000 \text{ m}^2)$ je stejná jako plocha mezi hodnotami -1 a 1 u rozdělení $N(0, 1)$. Tedy:

$$P(2\,800 \leq x \leq 4\,000) = P(-1 \leq z \leq 1)$$

Příklad - řešení d)

Od plochy před hodnotou 1 odečteme plochu před hodnotou -1, proto:



$$P(-1 \leq z \leq 1) = P(z \leq 1) - P(z \leq -1) = P(z \leq 1) - [1 - P(z \leq 1)] = 0,84134 - [1 - 0,84134] = 0,68268$$



Binomické rozdělení

Příklad

Třikrát hodíme kostkou. Jaká je pravděpodobnost, že šestka nepadne, že padne jednou, dvakrát, třikrát?



Binomické rozdělení

- rozdělení diskrétní náhodné proměnné
- udává rozdělení výsledků jednoho a téhož pokusu za stejných podmínek
- výsledkem pokusu mohou být pouze dvě alternativy (A nebo B)
- pravděpodobnost varianty A značíme p , pravděpodobnost varianty B značíme q
- pokus provedeme n -krát a hledáme pravděpodobnost, že alternativa A nastane právě x -krát
- rozdělení pravděpodobnosti

$$f(x) = \binom{n}{x} \cdot p^x \cdot q^{n-x} = \frac{n!}{x!(n-x)!} \cdot p^x \cdot q^{n-x}$$

Binomické rozdělení

Předpoklady pro vznik náhodné proměnné s binomickým rozdělením:

- provádíme n pozorování nebo pokusů
- pozorování nebo pokusy jsou nezávislé - znalost výsledku v jednom pozorování nebo pokusu nám nic neříká o výsledku jiného pozorování
- výsledky pozorování nebo pokusu mohou být jenom dva, nazveme je „úspěch“ a „neúspěch“
- pravděpodobnost p každého „úspěchu“ je stejná pro všechna pozorování nebo pokusy

Binomické rozdělení

Základní charakteristiky binomického rozdělení

$$\mu = n \cdot p$$


$$\sigma^2 = n \cdot p \cdot q$$

Příklady použití binomického rozdělení v geografii

- rozdělení počtu dní s určitým meteorologickým jevem za měsíc
- pravděpodobnost narození dvou chlapců v rodinách se třemi dětmi
- pravděpodobnost pozdního příchodu na jednu z přednášek statistiky
- ...

Binomické rozdělení

Rozdělení pravděpodobnosti binomického rozdělení pro $n = 8$ a různé hodnoty pravděpodobnosti p :



Příklad

Znalostní test sestává z otázek s několika volitelnými odpověďmi. Předpokládejme, že student má pravděpodobnost 0,55, že správně odpoví na otázku náhodně zvolenou ze sestavy otázek. Správnost odpovědi na specifickou otázku nezáleží na ostatních otázkách. Test obsahuje 20 otázek. Odhadněte pravděpodobnost, s jakou student odpoví aspoň 14 otázek správně.

Řešení

$$f(x) = \binom{n}{x} \cdot p^x \cdot q^{n-x} =$$
$$\binom{20}{14} \cdot 0,55^{14} \cdot 0,45^6 + \dots + \binom{20}{20} \cdot 0,55^{20} \cdot 0,45^0 = 0,1299$$

Poissonovo rozdělení

- rozdělení diskrétní náhodné proměnné
- pojmenováno po francouzském matematikovi S. D. Poissonovi (1781–1840)
- náhodná veličina může nabývat hodnot $x = 0, 1, 2, 3, \dots$ (kolikrát daný jev nastal v určitém časovém okamžiku) a to s pravděpodobnostní funkcí

$$f(x) = \frac{\lambda^x \cdot e^{-\lambda}}{x!}$$

- platí $\mu = \sigma^2 = \lambda$, kde $\lambda = n \cdot p$ je jediným parametrem tohoto rozdělení

Poissonovo rozdělení


Předpoklady pro použití tohoto rozdělení:

- pravděpodobnost výskytu jedné události v daném intervalu (čase nebo prostoru) je úměrná délce tohoto intervalu
- události se vyskytují nezávisle jak ve stejném intervalu, tak mezi po sobě jdoucími intervaly
- událost může nastat v kterémkoliv okamžiku
- výskyt dvou či většího počtu událostí během krátkého časového okamžiku (ale i v malém prostoru) je prakticky nemožný

Poissonovo rozdělení

Příklady použití Poissonova rozdělení

- počet ztracených dětí v obchodním domě v určitém časovém úseku
- počet telefonních hovorů v určitém časovém úseku
- počet borovic na jednotku plochy smíšeného lesa
- počet tiskových chyb na jedné straně textu



Příklad

Předpokládejme, že průměr počtu těžkých zranění v jednom ročníku hokejové ligy je 5. Rozdělení četností zranění budeme modelovat pomocí Poissonova rozdělení. Máme zjistit, jaká je pravděpodobnost, že počet těžkých zranění bude více než 4.

Řešení

$$f(x) = \frac{\lambda^x \cdot e^{-\lambda}}{x!} = \frac{5^x \cdot e^{-5}}{x!}$$

Dosazením pro $x = 0, 1, 2, 3, 4$ získáme

$f(0) = 0,00674$, $f(1) = 0,03370$, $f(2) = 0,08425$, $f(3) = 0,14042$, $f(4) = 0,17552$. Tyto pravděpodobnosti sečteme a dostaneme hodnotu 0,44.

Hledaná pravděpodobnost, že počet zraněných přesáhne 4, má tedy hodnotu $1 - 0,44 = 0,56$.


χ^2 rozdělení $\chi^2(n)$

- ze základního souboru s normovaným normálním rozdělením provedeme náhodný výběr n prvků, které označíme x_1, x_2, \dots, x_n
- náhodná veličina představující součet čtverců těchto hodnot se řídí Pearsonovým χ^2 rozdělením s n stupni volnosti (stupně volnosti budeme vždy označovat ν)
- hodnota χ^2 může nabývat v různých výběrech různých hodnot v intervalu $(0, \infty)$
- jediným parametrem je n rozsah souboru a označuje počet stupňů volnosti
- s roustoucím rozsahem náhodného výběru se rozdělení blíží normálnímu rozdělení

χ^2 rozdělení


Příklady použití χ^2 rozdělení

- v teorii odhadu parametrů základního souboru
- při testování statistických hypotéz
- při ověřování předpokladu o shodě teoretického a empirického rozdělení
- ...



Studentovo t rozdělení

- spojité rozdělení pravděpodobnosti, které umožňuje i na základě souborů dat s malými rozsahy, u kterých nelze hovořit o asymptoticky normálním rozdělení, dělat přijatelné závěry
- Studentovo t rozdělení má jeden parametr a tím je opět rozsah souboru
- využívá se především pro testování hypotéz



Fisher-Snedecorovo rozdělení


- uvažujme dvě nezávislé náhodné veličiny, které mají χ^2 rozdělení s ν_1 a ν_2 stupňů volnosti
- poměr

$$F = \frac{X_1/n_1}{X_2/n_2}$$

má F rozdělení

- nabývá pouze kladných hodnot, má dva parametry ν_1 a ν_2
- používá se u testů hypotéz, při analýze rozptylu a v regresní analýze

Fisher-Snedecorovo rozdělení



Exponenciální rozdělení

- udává dobu čekání na příchod nějaké události, která se může dostavit každým okamžikem se stejnou šancí bez ohledu na dosud pročekanou dobu
- hustota pravděpodobnosti (frekvenční funkce) tohoto rozdělení má následující tvar pro $x > 0$:


$$f(x) = \lambda e^{-\lambda x}$$

- rozdělení má jeden parametr λ - velké hodnoty indikují velký sklon hustoty pravděpodobnosti a naopak
- střední hodnota je rovna $\frac{1}{\lambda}$ a rozptyl $\frac{1}{\lambda^2}$

Exponenciální rozdělení

- hodnoty pravděpodobnosti lze určovat přímo z distribuční funkce

$$F(x) = p(X < x) = 1 - e^{-\lambda x}$$



Příklad

40 studentů dojíždí do školy z průměrné vzdálenosti 7 km. Histogram hodnot vzdálenosti vykazuje pozitivní asymetrii. Hodnota parametru exponenciálního rozdělení bude $\lambda = \frac{1}{7} = 0,143$. Jaká je pravděpodobnost, že student dojíždí ze vzdálenosti 15 km a delší?

$$p(15 > x) = 1 - p(15 < x) = 1 - [1 - e^{-0,143 \cdot 15}] = e^{-2,145} = 0,117068$$


Lognormální rozdělení

- proměnná X má lognormální rozdělení pravděpodobnosti, když logaritmickou transformací $Y = \ln X$ získá rozdělení normální s parametry μ a σ

$$f(x) = \frac{1}{x\sqrt{2\pi\sigma^2}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$$

- používá se při rozdělení věku obyvatelstva v populaci, při stopové analýze (koncentraci stopových prvků v horninách), ...

Lognormální rozdělení



Děkuji za pozornost...