

Statistické metody a zpracování dat

III. Pravděpodobnost, teoretická rozdělení

Petr Dobrovolný



Pravděpodobnost, náhodná proměnná

- Dospod probané postupy statistické analýzy – popisné a průzkumové (explorační) metody – umožňují přehledné shrnutí informací, které se týkají objektů měřených či pozorovaných.
- Činíme závěry pouze z určitého zpracovávaného souboru – výběrového, popisujeme jen to, co bylo zjištěno, naměřeno.
- S popisnou statistikou často nevystačíme, potřebujeme činit zobecňující úsudky.

Příklady:

- Jak často se takováto povodeň může opakovat?
- Jakou hodnotu měřené veličiny nejpravděpodobněji získáme opakováním měření?
- Je vysoký počet dvojčat narozených v určitém okrese „normální“?
- Je rozdíl mezi dvěma jevy významný?

Pravděpodobnost, náhodná proměnná

Přírodní či společenské jevy mohou mít povahu jevů

- **deterministických** – za určitého souboru podmínek se dostaví vždy stejný výsledek (př. voda poteče vždy ve směru největšího sklonu)
 - **náhodných** - za určitého souboru podmínek může nastat jeden z konečně či nekonečně množiny výsledků. Tento výsledek závisí nejen na vstupních podmínkách, ale obsahuje i prvek náhody (tahání karet, měření teploty vzduchu, ...).
- Náhodná veličina – proměnná, u které nelze na základě určité zákonitosti předem stanovit její konkrétní hodnotu.
- Řada jevů a procesů studovaných v geografických disciplínách má charakter **náhodné proměnné**.
 - Řada geografických jevů má **pravděpodobnostní charakter** (mohou nastat s určitou pravděpodobností) – např. výsledky prognóz (demografie, meteorologie apod.)
 - Použití teorie pravděpodobnosti (např. pro testování, odhady) vyžaduje data získaná náhodným výběrem (náhodné proměnné).

Náhodný jev

- za daných podmínek se může či nemusí vyskytnout.
- náhodný pokus, při kterém můžeme dostat různé výsledky a přitom:
 - nelze předem určit, který z výsledků získáme
 - pokus lze libovolně často opakovat, přičemž jednotlivá opakování se vzájemně neovlivňují

Náhodná proměnná:

Náhodná proměnná – předpis, který každému výsledku náhodného jevu (pokusu) přiřazuje určité číslo. Značí se velkými písmeny (A,X,Z).

- **Spojitá** – může nabývat jakékoli hodnoty z určitého intervalu (teplota vzduchu)
- **Diskrétní** – může nabývat pouze konkrétních hodnot (házení kostkou, polohování narozeného dítěte)

Pravděpodobnost



- Pravděpodobnost jako vyjádření míry nejistoty o výskytu náhodného jevu, o výsledku náhodného jevu.
- Pravděpodobnost, že nastane určitý náhodný jev se pohybuje v intervalu <0,1> resp. <0,100> %.
- **Jev možný** – množina všech možných výsledků - náhodný jev
- **Jev jistý** – padne něco mezi 1 až 6
- **Jev nemožný** – padne 7
- **Jev elementární** – padne 6
- **Jev složený** – více možných výsledků (padne sudé číslo)

Podmíněná pravděpodobnost $P(A|B)$ – pravděpodobnost jevu A za předpokladu, že nastane jev B

Pravděpodobnost

$P(A)$ - Určení pravděpodobnosti P, s jakou náhodný jev A nastane, můžeme povést dvěma způsoby:

1. Určení pravděpodobnosti „a priori“:

Podíl počtu požadovaných výsledků a počtu všech možných výsledků:
Př.: S jako pravděpodobností padne při házení kostkou šestka:

$$P(A) = \frac{m}{n}$$

A – jev který sledujeme
 $P(A)$ – pravděpodobnost jevu A
 m – Počet požadovaných výsledků
 n – počet všech možných výsledků

V našem případě: $P(A=6)$: m=1 (šestku můžeme hodit jen jedním způsobem), n=6 (může padnout 6 různých čísel, tedy:

$$P(A = 6) = \frac{m}{n} = \frac{1}{6} = 0,1667$$

Pravděpodobnost, že při hodu kostkou padne šestka je 16,67%

Pravděpodobnost

2. Určení pravděpodobnosti „a posteriori“:
Pomocí relativní četnosti výskytu studovaného jevu:

$$P(A) = \frac{n_i}{n}$$

n_i – počet požadovaných výsledků, které nastaly při realizaci jevu (absolutní četnost)
 n – celkový počet pokusů (rozsah souboru)

Příklad: Z deseti hodů kostkou ($n=10$) jsme získali následující výsledky: 2,4,6,1,6,3,5,6,2,1. Spočteme frekvenci výskytu jednotlivých výsledků a následně relativní četnost výsledku, při kterém padla šestka, tedy počet případů příznivých jevu A k počtu případů možných.

$$P(A = 6) = \frac{n_i}{n} = \frac{3}{10} = 0,3$$

Empiricky zjištěná pravděpodobnost, že padne 6 je 30%.


Obě pravděpodobnosti se liší. Čím více realizací náhodného pokusu provedeme, tím si budou výsledky blížší, pro $n \rightarrow \infty$ budou shodné.

Některá pravidla pro počítání s pravděpodobnostmi

- Pravděpodobnost jistého jevu je jedna.
- Pravděpodobnost nemožného jevu je nula.
- Pravděpodobnost sjednocení dvou vzájemně neslučitelných (disjunktivních) jevů A a B je rovna součtu jejich pravděpodobností:
platí-li $A \cap B = \emptyset$, potom $P(A \cup B) = P(A) + P(B)$.
- Pro pravděpodobnost sjednocení jevů A a B, které se vzájemně nevylučují, platí, že se rovná součtu pravděpodobností obou jevů zmenšenému o pravděpodobnost jejich průniku.
platí-li $P(A \cap B) \neq 0$, potom $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- Pravděpodobnost současného objevení dvou nezávislých jevů (jejich průniku) je rovna součinu pravděpodobnosti těchto jevů:
$$P(A \cap B) = P(A) \cdot P(B)$$
- Pro pravděpodobnosti dvou opačných jevů platí, že jejich součet je 1:
$$P(\bar{A}) = 1 - P(A)$$

Rozdelení náhodné proměnné

- Každému výsledku náhodného jevu či procesu přísluší určitá pravděpodobnost.
- Můžeme určit s jakou pravděpodobností náhodný jev nabývá určité výsledné hodnoty či hodnoty z určitého intervalu.



Teoretická rozdelení

Důležité pojmy:
Pro diskrétní náhodnou proměnnou konstruujeme:

- rozdelení pravděpodobností diskrétní náhodné proměnné
- distribuční funkci diskrétní náhodné proměnné


Pro spojitou náhodnou proměnnou konstruujeme:

- hustotu pravděpodobností spojité náhodné proměnné
- distribuční funkci spojité náhodné proměnné

Rozdelení pravděpodobnosti $f(x)$ náhodné proměnné X je funkce $f(X)$, která každé hodnotě X přiřazuje určitou pravděpodobnost $p(x)$, se kterou tato nabývá konkrétní velikosti

Teoretická rozdelení spojité náhodné veličiny

K tzv. **frekvenční funkci $f(x)$** . Můžeme dospět jednoduše z histogramu relativních četností




Frekvenční funkce $f(x)$ představuje teoretické rozdelení četnosti základního souboru parametry μ, σ .

Cíl – nahradit výběrové soubory základními a pro ně odvozovat potřebné charakteristiky

(Příklad - hodnocení stupně normality výskytu určitých hodnot – povodně)

Teoretická rozdelení spojité náhodné veličiny

Analogicky lze ze součtové čáry definovat tzv. **distribuční funkci $F(x)$** .



Distribuční funkce udává pravděpodobnost, se kterou náhodná proměnná nabývá hodnoty menší nebo rovné určité konkrétní velikosti x.


$$F(x) = P(X < x) = \sum_{x_i < x} P(X = x_i)$$

Normální rozdělení

- Nejčastěji používané rozdělení spojité náhodné veličiny.
- Opakované měření stejné veličiny za stejných podmínek.
- Naměřené veličiny více méně kolísají kolem skutečné hodnoty
- Má dva parametry μ , σ .


Frekvenční funkce:

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




Distribuční funkce:

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



Normální rozdělení




Normované normální rozdělení

Protože se μ i σ výběru liší, má i frekvenční funkce (normální křivka) různý tvar. Proto se zavádí tzv. **normovaná náhodná proměnná**

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

Normované normální rozdělení již potom nezáleží na parametrech μ i σ a jeho frekvenční a distribuční funkce mají následující tvar:



Normované normální rozdělení

Pro hodnoty distribuční funkce $F(x)$ normálního rozdělení $N[\mu, \sigma]$ a hodnoty distribuční funkce $F(z)$ normovaného normálního rozdělení $N[0, 1]$ platí:


$$\text{Jestliže } z_0 = \frac{x_0 - \mu}{\sigma} \text{ potom } F(x_0) = F(z_0)$$

Obsahy ploch pod křivkami hustoty navzájem si odpovídajících si hodnot $F(x_0) = F(z_0)$ jsou stejné (a tedy stejně jsou i pravděpodobnosti výskytu těchto hodnot). Například:

$$\text{Protože } z_0 = \frac{x_0 - \mu}{\sigma} = \frac{4000 - 3400}{600} = 1 \text{ potom } P(x \leq 4000) = P(z \leq 1) = 0,84134$$


$N[3400, 600], x_0 = 4000$

$N[0, 1], x_0 = 1$



Hlavní vlastnosti normální křivky:

- zvonovitý tvar, asymptoticky se blíží k ose x, může nabývat hodnot ()
- souměrná podle osy procházející jejím vrcholem. x-ová souřadnice vrcholu je aritmetickým průměrem
- aritmetický průměr, medián a modus se rovnají
- s osou x omezuje normální křivka plochu o velikosti 100 % (1)




Pomocí násobků směrodatné odchyly lze stanovit pravděpodobnosti, s nimiž leží hodnoty v určitém intervalu:

Vlastnosti normální křivky:

a naopak

- 95% pravděpodobnosti odpovídá interval $\mu \pm 1,96\sigma$
- 99% pravděpodobnosti odpovídá interval $\mu \pm 2,58\sigma$



Stanovení mezí extremity

Slovní označení extremity	Symbol	Meze	Pravděpodobnost výskytu jevu (%)	Meze	Pravděpodobnost výskytu jevu (%)
extrémně podnormální	EP	$\zeta \bar{x} - 3s$	0,135	$\zeta \bar{x} + 3s$	2,15
silně podnormální	SP	$\bar{x} - 3s \leq \bar{x} \leq \bar{x} + 3s$	2,190	$\bar{x} - 3s \leq \bar{x} \leq \bar{x} + 3s$	8,87
podnormální	P	$\bar{x} - 2s \leq \bar{x} \leq \bar{x} + 2s$	13,590	$\bar{x} - 2s \leq \bar{x} \leq \bar{x} + 2s$	13,98
normální	O	$\bar{x} - s \leq \bar{x} \leq \bar{x} + s$	68,270	$\bar{x} - s \leq \bar{x} \leq \bar{x} + s$	50,00
nadnormální	N	$\bar{x} + s \leq \bar{x} \leq \bar{x} + 2s$	13,590	$\bar{x} + s \leq \bar{x} \leq \bar{x} + 2s$	13,98
silně nadnormální	SN	$\bar{x} + 2s \leq \bar{x} \leq \bar{x} + 3s$	2,190	$\bar{x} + 2s \leq \bar{x} \leq \bar{x} + 3s$	8,87
extrémně nadnormální	EN	$\bar{x} + 3s \leq \bar{x}$	0,135	$\bar{x} \geq \bar{x} + 3s$	2,15

Příklad použití


- Pro danou hodnotu jevu hledáme pravděpodobnost její výskytu.
 - Pro zadanou pravděpodobnost hledáme hodnotu studovaného jevu.
- Dvě možnosti výpočtu
- převod na normované normální rozdělení a využití statistických tabulek
 - pomocí sv modelujícího hodnoty $f(x)$ a $F(x)$ příslušného rozdělení

Příklad: Plochu obhospodařované zemědělské půdy u sledovaného souboru farmářů modelujeme normálním rozdělením. Zjistili jsme, že parametry rozdělení $N [3400 m^2, 600 m^2]$. Vypočtěte pravděpodobnost, že náhodně vybraný zemědělec bude mít:

- méně než $4000 m^2$ půdy
- více než $4200 m^2$ půdy
- méně než $3000 m^2$ půdy
- mezi 2800 a $4000 m^2$ půdy



Příklad řešení při použití tabulek distribuční funkce normovaného normálního rozdělení




Ad b) Farmář má více než $4200 m^2$ půdy

Transformace hodnoty x na normovanou veličinu z (z-skóre):

$$z = \frac{x - \mu}{\sigma} = \frac{4200 - 3400}{600} = 1,33$$

Pravděpodobnost, že normovaná proměnná překročí hodnotu 1,33 v tabulkách není. Určujeme obsah plochy pod křivkou hustoty rozdělení za hodnotou 1,33:

$$P(x \geq 4200) = P(z \geq 1,33) = 1 - P(z \leq 1,33) = 1 - 0,90824 = 0,09176$$




Ad c) Farmář má méně než $3000 m^2$ půdy

Transformace hodnoty x na normovanou veličinu z (z-skóre):

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

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

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



Ad d) Farmář má mezi 2800 a 4000 m² půdy

Transformace hodnoty x na normovanou veličinu z (z-skóre):

$$z_1 = \frac{x_1 - \mu}{\sigma} = \frac{2800 - 3400}{600} = -1 \quad z_2 = \frac{x_2 - \mu}{\sigma} = \frac{4000 - 3400}{600} = 1$$


Plocha mezi hodnotami 2800 a 4000 m² u rozdělení $N[3400, 600]$ je stejná jako plocha mezi hodnotami -1 a 1 u rozdělení $N[1, 0]$.

$$P(2800 \leq x \leq 4000) = P(-1 \leq z \leq 1)$$

Od plochy před hodnotu 1 odečteme plochy před hodnotou -1, tedy:


$$P(-1 \leq z \leq 1) = P(z \leq 1) - P(z \leq -1) =$$

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




Řešení při použití pomocí sw modelujícího hodnoty f(x)

a F(x) příslušného rozdělení



STATISTICA – Pravděpodobnostní kalkulačka

Řešení při použití pomocí sw modelujícího hodnoty f(x) a F(x) příslušného rozdělení



EXCEL – soubor PDF – viz. studijní materiály v IS

Pearsonova křivka III. typu


- Na řadu souborů geografických údajů nelze aplikovat normální rozdělení.
- Je to v případech, že studovaná veličina nemá teoreticky zdůvodněnou možnost nabývat nekonečných hodnot či je omezena z obou stran konečnými čísly.
- V těchto případech lze často využít některé z 12 křivek Pearsonovy systému.
- Především v meteorologii a klimatologii se ke konstrukci tzv. čar překročení využívají Pearsonovy křivky III. typu.

Průběh křivky je určen třemi parametry:

- aritmetickým průměrem
- variačním koeficientem
- koeficientem asymetrie

Pearsonova křivka III. typu

Tvar rovnice:



Hodnota y_0 značí největší pořadnice křivky a odpovídá modu rozdělení. b – vzdálenost pořadnice procházející aritmetickým průměrem od y_0 , a – vzdálenost y_0 od počátku křivky.

Čára překročení

Čára překročení je součtová čára četnosti a lze z ní stanovit pravděpodobnost, se kterou bude znak určité hodnoty dosažený a překročený (či nebude dosažený).

Ke konstrukci čáry překročení musíme znát tři parametry:

Spočteme aritmetický průměr

Označíme-li $\frac{x_i}{\bar{x}} = k_i$ potom variační koeficient bude: $v = \sqrt{\frac{\sum (k_i - 1)^2}{n-1}}$


Koeficient asymetrie je roven $\alpha = \frac{2b}{v}$ a nebo $\alpha = \frac{\sum (k_i - 1)^3}{(n-1) \cdot v^3}$

a nebo $\alpha = 2v$

Uvedená podmínka je často nutná pro fyzikálně zdůvodnitelné výsledky

Čára překročení

Tvar čáry překročení pro různá α



Konstrukce čáry překročení I

1) Seřadíme hodnoty R_i v klesajícím pořadí

2) Vypočteme aritmetický průměr \bar{R}

3) Stanovíme hodnoty $k_i = \frac{R_i}{\bar{R}}$

4) Vypočteme výrazy $(k_i - 1)$, $(k_i - 1)^2$, $(k_i - 1)^3$ a jejich sumy

5) Vypočteme hodnoty variačního koeficientu a koeficientu asymetrie α

A	B	C	D	E	F	G	H	I	J	K	T
Períod	Rok	Ri	ki	ki-1	(ki-1) ²	(ki-1) ³	m	P%	Pc		
1	1980	90.5	2.00	1.762	3.0256	1.1768	1	1.78	0.02	90	
2	1977	88.5	1.987	0.967	0.9305	0.904	2	4.17	0.04	90	
3	1979	82.5	1.949	0.949	0.720	0.611	3	6.95	0.07	16	
4	1998	51.5	1.523	0.523	0.274	0.143	4	9.39	0.09	11	
5	
6	
7	
8	36	1998	19.6	0.580	-0.420	0.177	-0.074	36	90.61	0.91	1
9	37	1976	19.2	0.568	-0.432	0.187	-0.081	37	93.15	0.93	1
10	38	1990	18.4	0.544	-0.456	0.208	-0.095	38	95.69	0.96	1
11	39	1994	15.9	0.470	-0.530	0.281	-0.149	39	98.22	0.98	1

$$v = \sqrt{\frac{\sum (k_i - 1)^2}{n-1}} = 0,447 \quad \alpha \approx 2v = 0,90$$

$$P_c = \frac{m-0,3}{n+0,4}$$

$$T = \frac{1}{P_c}$$

doba opakování


Konstrukce čáry překročení II

- Pro jednotlivé hodnoty pravděpodobnosti překročení p a pro vypočtenou hodnotu koeficientu asymetrie α vypočteme pomocí tabelovaných hodnot E pro případ $v = 1$ pořadnice čáry překročení – teoretické hodnoty R .
- Každé hodnotě R odpovídá určité doba opakování (T)

Pravděpodobnosti překročení pro koeficient asymetrie 0,9


P	E $(E^v v) + 1$	R	T
0.01	5.73	3.56	120.52
0.1	4.38	2.98	100.09
1	2.98	2.32	78.60
3	2.22	1.99	87.41
5	1.86	1.83	81.98
10	1.34	1.60	54.09
20	0.77	1.34	45.46
25	0.57	1.26	42.44
30	0.40	1.18	39.86
40	0.11	1.05	35.47
50	-0.15	0.93	31.54
60	-0.36	0.83	28.06
70	-0.61	0.73	24.58
75	-0.73	0.67	22.76
80	-0.85	0.62	20.95
90	-1.15	0.49	18.41
95	-1.35	0.40	13.38
97	-1.47	0.34	11.56
98	-1.66	0.26	8.89
99.9	-1.90	0.15	5.06

Konstrukce čáry překročení III



Hodnocení extremity jevu na základě procenta pravděpodobnosti překročení určeného z čáry překročení:


Pravděpodobnost	Jev je	Symbol
0 - 10	extrémně nadnormální	EN
11 - 20	velmi silně nadnormální	VN
21 - 33	silně nadnormální	SN
34 - 45	nadnormální	N
46 - 55	normální	O
56 - 67	podnormální	P
68 - 80	silně podnormální	SP
81 - 90	velmi silně podnormální	VP
91 - 100	extrémně podnormální	EP



Křivka překročení průměrných ročních průtoků Dunaje v Bratislavě v období 1901-1950 a hodnocení hodnotnosti roků

Rozdělení diskrétní náhodné proměnné

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, kdy výsledkem pokusu mohou být pouze dvě alternativy A nebo B.

Pravděpodobnost, že nastane alternativa A značíme p , pravděpodobnost, že nastane alternativa B značíme q .

Přitom platí: $p + q = 1$


Pokus provedeme n -krát a hledáme pravděpodobnost, že alternativa A nastane právě x -krát. Výpočet této pravděpodobnosti určuje výraz:

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

Uvedený vztah vyjadřuje rozdělení pravděpodobností binomického rozdělení (analogie frekvenční funkce u spojitéch veličin).

Binomické rozdělení

U binomického rozdělení nabývá náhodná veličina diskrétních hodnot od 0 do n .



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

Je-li $p = q = 0,5$, potom je binomické rozdělení souměrné

Základní momenty binomického rozdělení

$$\mu = n \cdot p \quad \sigma = \sqrt{n \cdot p \cdot q} \quad \alpha = \frac{1 - 2p}{\sqrt{n \cdot p \cdot q}} \quad \varepsilon = \frac{1 - 6p \cdot q}{n \cdot p \cdot q}$$

Příklady použití binomického rozdělení

- rozdělení počtu dní s určitým meteorologickým jevem za měsíc
- pravděpodobnost narození dvou chlapců v rodinách se třemi dětmi
- pravděpodobnost pozdního příchodu na jednu ze 12 přednášek ze statistiky

Binomické rozdělení

Příklad: Pravděpodobnost, že se v určitém roce vyskytne na studovaném toku povodeň je 0,25. Jaká je pravděpodobnost, že se během příštích čtyř let vyskytou 3 povodně?



- každý rok je nezávislý „pokus“
- každý rok se povodeň může vyskytnout či nemusí
- pravděpodobnost výskytu povodně $p=0,25$
- pro 4 roky ($n=4$) hledáme pravděpodobnost výskytu tří povodní ($x=3$)

$$f(x) = \binom{n}{x} \cdot p^x \cdot q^{n-x} = \binom{4}{3} \cdot 0,25^3 \cdot 0,75^{4-3} = 0,0469$$

Pravděpodobnost výskytu tří povodní ve 4 ročích je necelých 5 procent.

Binomické rozdělení

Binomial Distribution (for a variable K)

Parameters

Number of Trials (n) 4

Probability of a Success (p) 0.25

Probability

Number of "Successful" Outcomes (k) 3


P($K = k$) =	0.0469
P($K \leq k$) =	0.95609
P($K \geq k$) =	0.05078
P($K < k$) =	0.94922
P($K > k$) =	0.00391

k pdf

0	0.316406
1	0.421675
2	0.210938
3	0.046875
4	0.003906

k cdf

0	0.316406
1	0.730281
2	0.940219
3	0.996094
4	1



Příklad – pokračování

Pravděpodobnostní funkce

Distribuční funkce

Poissonovo rozdělení

Popisuje pravděpodobnost výskytu **vzácných jevů**. Je vhodné v případech, kdy p v binomickém rozdělení je příliš malé nebo naopak příliš blízké 1.

Náhodná veličina s Poissonovým rozdělením může nabývat hodnot $x = 0, 1, 2, 3, \dots$ (kolikrát jev nastal v určitém časovém úseku) a to s rozdělením pravděpodobnosti:

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

Pro aritmetický průměr a rozptyl platí: $\mu = \sigma^2 = \lambda$

kde λ je očekávaná hodnota a jediný parametr Poissonova rozdělení: $\lambda = n \cdot p$

Označuje se jako rozdělení vzácných případů (bouřky v zimě, výskyt krupobití v roce, ...). Jeho použití se doporučuje, pokud $n > 30$ (resp. 50) a $p \leq 0,1$ nebo $p \geq 0,9$.


Poissonovo rozdělení

Použití tohoto rozdělení lze charakterizovat následujícími vlastnostmi:

- Pravděpodobnost výskytu jedné události v daném intervalu (času 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

Použití:

- počet dětí ztracených v obchodním domě v určité časovém úseku
- počet telefonních hovorů v určitém časovém úseku
- počet borovic na jednotku plochy smíšeného lesa



S rostoucí hodnotou λ se tvar tohoto rozdělení blíží normálnímu

Poissonovo rozdělení - příklad



Průměrný počet těžkých dopravních nehod na určité křižovatce za měsíc je 5. Rozdělení četnosti nehod modelujeme Poissonovým rozdělením. Jaká je pravděpodobnost, že počet nehod bude více než 4.


- Rozdělení četnosti nehod obecně pro $x = 0, 1, 2, 3, 4$ má tvar:

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

- Vypočteme pravděpodobnosti $f(x)$ pro jednotlivá x : $f(0), \dots, f(4)$
- Součet těchto pravděpodobností je 0,44
- Hledaná pravděpodobnost – tedy že počet nehod přesáhne 4:

$$1 - 0,44 = 0,56$$

Poissonovo rozdělení – příklad (pokračování)



Rozdělení CHÍ - kvadrát χ^2

Ze základního souboru s normovaným normálním rozdělením provedeme náhodný výběr n prvků, které označíme x_1, x_2, \dots, x_n .

Součet čtverců těchto hodnot se označuje jako χ^2 („chí – kvadrát“):


$$\sum_{i=1}^n x_i^2 = \chi^2$$

Hodnota χ^2 může nabývat v různých výběrech různých hodnot v intervalu $(0; \infty)$ a má své vlastní rozdělení - rozdělení s vlastní frekvenční ($f_v(\chi^2)$) a distribuční funkcí ($F_v(\chi^2)$).

Symbol v značí počet stupňů volnosti a je jediným parametrem rozdělení. Je roven rozsahu náhodného výběru.

Každé hodnotě $v = n$ přísluší jiná křivka. S rostoucím v se rozdělení blíží rozdělení normálnímu.

Rozdělení CHÍ - kvadrát χ^2



Frekvenční funkce chí-kvadrát rozdělení pro různý počet stupňů volnosti

Použití:

- v teorii odhadu a testování hypotéz
- při ověřování předpokladu zda empirické rozdělení četnosti má určité teoretické pravděpodobnost rozdělení
- testování rozptylu dvou výběrových souborů při neznámé střední hodnotě
- při ověřování nezávislosti kvalitativních znaků
- pro testy nezávislosti v kontingenčních tabulkách.

Rozdělení t (Studentovo)

Využívá se především pro hodnocení odchylek hodnot aritmetického průměru základního souboru μ a aritmetického průměru výběrového souboru \bar{x} .

Pro hodnocení odchylek ($\bar{x} - \sigma$) se definuje náhodná veličina


$$t = \frac{\bar{x} - \mu}{\sigma} \sqrt{n-1}$$

Této přísluší tzv. *t-rozdělení* (Studentovo). Spojitá náhodná veličina t může nabývat hodnot $(-\infty; \infty)$. Frekvenční funkce $q_v(t)$ je souměrná podle osy procházející vrcholem a má jeden parametr $v = n-1$.

S rostoucím počtem stupňů volnosti se *t-rozdělení* blíží rozdělení normálnímu.

Theoreticky se shodují při $v = \infty$.

V praxi však postačuje $v > 30$.




Rozdělení F (Fisherovo-Snedecorovo)

Uvažujeme dvě nezávislé náhodné veličiny, které mají χ^2 rozdělení s v_1 a v_2 stupni volnosti. Veličina F , určená jako jejich poměr

$$F = \frac{\chi_1^2}{v_1} : \frac{\chi_2^2}{v_2}$$

má tzv. *F – rozdělení*.




Jak je patrné z obrázku, náhodná veličina F nabývá pouze kladných hodnot.

Frekvenční funkce $h_{v_1, v_2}(F)$ je nesymetrická s dvěma parametry v_1 a v_2 .

Používá se u testů v regresní analýze, při analýze rozptylu a při testu shody rozptylů dvou výběrů z normálního rozdělení.


Další v geografii využívaná teoretická rozdělení



- Gama rozdělení
- Gumbelovo rozdělení
- GEV (General Extreme Value)

Asymetrická rozdělení

- vzdálenosti na které se lidé stěhují, cestují na dovolenou, do práce ...
- osobní příjmy
- vzdálenost dojíždky



Většina této rozdělení má kladnou asymetrii

Nalezněte příklady pro rozdělení se zápornou asymetrií (?!)


Jak lze charakterizovat rozdělení takových veličin jako:

- počet členů domácnosti
- četnost zaměstnanců podle průměrné měsíční mzdy

Exponenciální rozdělení

Frekvenční funkce $f(x)$ má následující tvar a její sklon klesá s rostoucí hodnotou x

$$f(x) = \lambda e^{-\lambda x} \quad \text{pro} \quad x \geq 0$$



Rozdělení má jeden parametr (λ), jeho velké hodnoty indikují velký sklon frekvenční funkce a naopak.

Hodnoty pravděpodobnosti lze určovat přímo z distribuční funkce:

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

Očekávaná hodnota průměru je $1/\lambda$, a očekávaná hodnota rozptylu $1/\lambda^2$. Z očekávané hodnoty průměru potom lze určit hodnotu parametru (λ).

Hodláme-li výběrovým souborem, který má silně pozitivní asymetrii proložit exponenciální rozdělení, určíme průměrnou hodnotu výběrového souboru a parametr rozdělení λ bude jeho převrácenou hodnotou.

Exponenciální rozdělení - příklad

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

Exponential Distribution (for a variable T)


Parameters
Failure Rate (λ) **0.143**

Probability
Value of Variable (t) **15**

$$\begin{aligned} P(T = t) &= 0 \\ P(0 \leq T \leq t) &= 0.88293 \\ P(T \geq t) &= 0.11707 \end{aligned}$$

Inverse Probability


$$\begin{aligned} P(T \leq t) &= 0.95 \\ t &= 20.9492 \\ P(T \geq t) &= 0.05 \\ t &= 20.9492 \end{aligned}$$



Lognormální rozdělení

Proměnná X má lognormální rozdělení pravděpodobnosti, když logaritmickou transformací ($Y=\ln X$) získá právě rozdělení normální s parametry μ a σ^2 .

$$\text{Frekvenční funkce log-normálního rozdělení: } f(x) = \frac{1}{x\sqrt{2\pi\sigma^2}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$$




Příklady:

- rozdělení věku obyvatelstva v populaci
- koncentrace stopových prvků v horninách (stopová analýza),

Beta rozdělení U - rozdělení

α, β – parametry tvaru rozdělení
A,B – dolní a horní mez




Limitní věty (dobrá zpráva)

Formuluj obecná tvrzení o teoretických rozděleních v případě rostoucího rozsahu výběrového souboru (n)

Zákon velkých čísel

S rostoucím počtem pokusů se empirické rozdělení blíží teoretickému (relativní četnost se blíží pravděpodobnosti).


Střední hodnotu náhodné veličiny můžeme odhadovat průměrem z počtu dostatečně velkého pozorování



Centrální limitní věta

Pravděpodobnostní rozdělení náhodné veličiny, která vznikla jako součet velkého počtu vzájemně nezávislých náhodných veličin, je možné approximovat rozdělením normálním, i když výchozí dílčí náhodné veličiny mají rozdělení různá.

Rozdělení takovéto náhodné veličiny se totiž blíží k normálnímu rozdělení jako limitnímu, pokud je počet dílčích veličin dostatečně velký.



Pro dostatečně velké n můžeme binomické rozdělení approximovat normálním