

2. Základní typy dat



Spojitá a kategoriální data
Základní popisné statistiky
Frekvenční tabulky
Grafický popis dat

Anotace



- Realitu můžeme popisovat různými typy dat, každý z nich se specifickými vlastnostmi, výhodami, nevýhodami a vlastní sadou využitelných statistických metod - od binárních přes kategoriální, ordinální až po spojité data roste míra informace v nich obsažené.
- Základním přístupem k popisné analýze dat je tvorba frekvenčních tabulek a jejich grafických reprezentací – histogramů.

Jak vznikají informace ?

– různé typy dat znamenají různou informaci

Data poměrová

Kolikrát ?



Data intervalová

O kolik ?



Data ordinální

Větší, menší ?



Data nominální

Rovná se ?

Kategoriální otázky

Diskrétní
data

Binární data
Otázky „Ano/Ne“

Spojité
data

Podíl
hodnot
větší/menší
než
specifikovaná
hodnota
?

Procenta
odvozené
hodnoty

Samotná znalost typu dat ale na dosažení informace nestačí

Jak vznikají informace ?

– různé typy dat znamenají různou informaci



Statistika středu

Data poměrová



PRŮMĚR

Spojitá
data

$Y = f$

Data intervalová



MEDIÁN

Data ordinální



Diskrétní
data

Data nominální

MODUS

X

Jak vznikají informace ?

– různé typy dat znamenají různou informaci



Data:

$$\{x_i\}_{i=1}^n$$

p-tý kvantil

$$q_p = x_j : |\{x_k : x_k \leq x_j\}| = p \cdot n$$

Průměr:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

Medián:

$$\tilde{x} = x_j : |\{x_k : x_k \leq x_j\}| = \frac{n}{2}$$

Rozptyl (výběrový):

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}$$

Modus:

$$\hat{x} = \max_j |\{x_k : x_k = x_j\}|$$


Směrodatná odchylka (výběrová):

$$s = \sqrt{s^2}$$


JAK vznikají informace ?

- opakovaná měření informují rozložením hodnot

Y: frekvence
absolutní / relativní



KOLIK se
naměřilo



CO se
naměřilo

X: měřený znak

Diskrétní data

Spojité data

Odvozená data: Pozor na odvozené indexy



Příklad I:

Znak X: Hmotnost

Znak Y: Plocha

Příklad II:

X: Průměrný počet výrobků v prodejně

Y: Odhad prostoru průměrně nabízeného k vystavení výrobku

průměr : (min - max)

X: 1,2 : (1,15 - 1,24)



+ / - 3,8 %

Y: 1,8 : (1,75 - 1,84)



+ / - 2,5 %

X/Y = 0,667 : $\left(\frac{1,15}{1,84} - \frac{1,24}{1,75} \right)$



+ / - 6,2 %

Nová veličina má jinou šířku rozpětí než ty, ze kterých je odvozená

Jak vznikají informace ?

- frekvenční tabulka jako základní nástroj popisu



DISKRÉTNÍ DATA

Primární data

0
0
1
2
1
1
3
1
1
2
2
.
. .
. .
. .
. .
n = 100



Frekvenční summarizace

N: 100 dětí (hemofiliků)
x: znak: počet krvácivých epizod za měsíc

x	n(x)	N(x)	p(x)	F(x)
0	20	20	0,2	0,2
1	10	30	0,1	0,3
2	30	60	0,3	0,6
3	40	100	0,4	1,0

n(x) – absolutní četnost x

N(x) – kumulativní četnost hodnot nepřevyšujících x;





$$N(x) = \sum_{t \leq x} n(t)$$

p(x) – relativní četnost; $p(x) = n(x) / n$

F(x) – kumulativní relativní četnost hodnot nepřevyšujících x; $F(x) = N(x) / n$

Jak vznikají informace ?

Grafické výstupy z frekvenční tabulky



Jak vznikají informace ?

- frekvenční tabulka jako základní nástroj popisu



SPOJITÁ DATA

Příklad: **x: koncentrace látky v krvi n = 100 pacientů**

Frekvenční summarizace

n = 100 opakování měření (100 pacientů)

x: koncentrace sledované látky v krvi (20 – 100 jednotek)

Primární data

Hodnoty pro n = 100 osob
1,21
1,48
1,56
0,31
1,21
1,33
0,33
.
. .
n = 100



interv	d(I)	n(I)	n(I)/n	N(x'')	F(x'')
<20, 40)	20	20	0,2	20	0,2
<40, 60)	20	10	0,1	30	0,3
<60, 80)	20	40	0,4	70	0,7
<80, 100)	20	30	0,3	100	1,0

d(I) – šířka intervalu

n(I) – absolutní četnost

n(I) / n – intervalová relativní četnost

N(x'') – intervalová kumulativní četnost do horní hranice X''


F(x'') – intervalová relativní kumulativní četnost do horní hranice X''

Jak vznikají informace ?


- frekvenční summarizace spojitých dat



Histogram



Výběrová distribuční funkce



$$f(x) = \frac{n(I) / n}{d(I)}$$

Intervalová
hustota
četnosti


$$F(x)$$

Intervalová
relativní
kumulativní
četnost


Počet zvolených tříd a velikost souboru určují kvalitu výstupu




$k = 10$ tříd




$k = 5$ tříd



$k = 20$ tříd




Histogram vyjadřuje tvar výběrového rozložení




$f(x)$

X




$f(x)$


X



X



X




X




X


Příklad: věk účastníků vážných dopravních nehod









Správný histogram ?



Pojem ROZLOŽENÍ - příklad spojitéch dat




Výběrové rozložení hodnot lze modelově popsat a definovat tak pravděpodobnost výskytu X



Distribuční funkce jako užitečný nástroj pro práci s rozložením



Plocha = relativní četnost




$\Phi(x)$... distribuční funkce

$$P(X \leq M) = \int_{-\infty}^M \varphi(x) d(x)$$

$$\int_{-\infty}^{\infty} \varphi(x) d(x) = 1$$

$F(x)$: Pravděpodobnost,
že se X vyskytuje
v intervalu M



Známe-li distribuční funkci, pak známe rozložení sledované veličiny.


Pro jakoukoli množinu hodnot (M) lze určit P , že X do této množiny patří.

Jak vznikají informace ?

- frekvenční summarizace spojitých dat



Grafické výstupy z frekvenční tabulky – spojité data



Uspořádání čísel podle velikosti a konstrukce rozložení umožňuje pravděpodobnostní zařazení každé jednotlivé hodnoty



KVANTIL

$X_{0.1}; X_{0.9}; X_{0.5}; X_0$


Otázka: Jak velké musí být X, aby 5 % všech hodnot bylo nad ním?




$\theta = 0,95 \dots$ Pravděpodobnost

Hledáme: $P(X \leq \quad) = 0,95 = \theta$

$$x_{\theta} = (X_{0,95}) = ?$$



$$F(x \quad) = \quad$$



Kvantil je číslo, jehož hodnota distribuční funkce je rovna P , pro kterou je kvantil definován

Jakékoli číslo na ose x je kvantilem