

Přednáška III.

Data, jejich popis a vizualizace

- ➔ Náhodný výběr, cílová a výběrová populace
- ➔ Typy dat
- ➔ Vizualizace různých typů dat
- ➔ Popisné statistiky



evropský
sociální
fond v ČR



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY




OP Vzdělávání
pro konkurenceschopnost



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ


Opakování – podmíněná pravděpodobnost



- ➔ Jak můžu vyjádřit podmíněnou pravděpodobnost jevu A za nastoupení jevu B?
- ➔ A co platí v případě nezávislosti těchto dvou jevů?

Opakování – celková pravděpodobnost

- Populaci můžeme rozdělit dle věku na tři skupiny: děti (H_0), dospělé v produktivním věku (H_1) a dospělé v postprodukčním věku (H_2), přičemž známe rozdělení populace, tedy známe $P(H_0)$, $P(H_1)$ a $P(H_2)$.



- Označme **jev A: stane se úraz**.
- Známe pravděpodobnost úrazu u dítěte, $P(A|H_0)$, u dospělého v produktivním věku, $P(A|H_1)$, a u dospělého v postprodukčním věku, $P(A|H_2)$.
- Jsme schopni pomocí vzorce pro celkovou pravděpodobnost spočítat **$P(A)$** ?

Opakování – diagnostické testy

- ➔ Co vyjadřují následující charakteristiky?
- ➔ Senzitivita
- ➔ Specificita
- ➔ Prediktivní hodnota pozitivního testu
- ➔ Prediktivní hodnota negativního testu

1. Jak vznikají data?

Jak vznikají data?

➔ Záznamem skutečnosti...



Jak vznikají data?

➔ Záznamem skutečnosti...

... kterou chceme dále studovat → smysluplnost?

... více či méně dokonalým → kvalita?

Jak vznikají data?

➔ Záznamem skutečnosti...

... kterou chceme dále studovat → smysluplnost?


(krevní tlak, glykémie × počet srdcí, počet domů)

... více či méně dokonalým → kvalita?


(variabilita = informace + chyba)

Cílová populace, výběrová populace

- **Cílová populace** – skupina subjektů, o které chceme zjistit nějakou informaci. Odpovídá základnímu prostoru Ω .
- **Experimentální vzorek** neboli **výběrová populace** – podskupina cílové populace, kterou pozorujeme, měříme a analyzujeme. Jakékoli výsledky chceme zobecnit na celou cílovou populaci. **Výběrová populace musí svými charakteristikami odpovídat cílové populaci (reprezentativnost)**. Toho můžeme docílit náhodným, ale i záměrným výběrem.



Popis cílové populace – popis pozorované variability



?

Reprezentativnost

Spolehlivost

Přesnost

2. Typy dat a jejich vizualizace

Typy dat


- ➔ **Kvalitativní** proměnná (kategoriální) – lze ji řadit do kategorií, ale nelze ji kvantifikovat, resp. nemá smysl přiřadit jednotlivým kategoriím číselné vyjádření.
- ➔ Příklady: pohlaví, HIV status, užívání drog, barva vlasů
- ➔ **Kvantitativní** proměnná (numerická) – můžeme jí přiřadit číselnou hodnotu.
Rozlišujeme dva typy kvantitativních proměnných:
 - ➔ **Spojité**: může nabývat jakýchkoliv hodnot v určitém rozmezí.
Příklady: výška, váha, vzdálenost, čas, teplota.
 - ➔ **Diskrétní**: může nabývat pouze spočetně mnoha hodnot.
Příklady: počet krevních buněk, počet hospitalizací, počet krvácivých epizod za rok, počet dětí v rodině.

Typy dat – příklady

Kvalitativní proměnná



Kvantitativní proměnná



Kvalitativní data lze dělit dále

- ➔ **Binární data** – pouze dvě kategorie typu ano / ne.

- ➔ **Nominální data** – více kategorií, které nelze vzájemně seřadit.
Nemá smysl ptát se na relaci větší/menší.

- ➔ **Ordinální data** – více kategorií, které lze vzájemně seřadit.
Má smysl ptát se na relaci větší/menší.

Kvalitativní data – příklady

➔ Binární data

- ➔ diabetes (ano/ne)
- ➔ pohlaví (muž/žena)
- ➔ stav (ženatý/svobodný)

➔ Nominální data


- ➔ krevní skupiny (A/B/AB/0)
- ➔ stát EU (Belgie/.../Česká republika/.../Velká Británie)
- ➔ stav (ženatý/svobodný/rozvedený/vdovec)

➔ Ordinální data


- ➔ stupeň bolesti (mírná/střední/velká/nesnesitelná)
- ➔ spotřeba cigaret (nekuřák/ex-kuřák/občasný kuřák/pravidelný kuřák)
- ➔ stadium maligního onemocnění (I/II/III/IV)

Kvantitativní data

- Mají větší **informační hodnotu** než data kvalitativní.
- Spojitá data mají větší informační hodnotu než data diskrétní.
- Větší informační hodnota znamená, že nám stačí méně pozorování na detekci určitého rozdílu (pokud ten rozdíl samozřejmě existuje).
- Kvůli interpretaci je někdy výhodné kvantitativní data **agregovat** do kategorií (např. věk) – **tímto krokem však ztrácíme část informace**. Zpětně nejsme schopni data rekonstruovat.



Typy dat dle škály hodnot



Další typy dat – odvozená data

- ➔ **Pořadí** (rank) – místo absolutních hodnot známe někdy pouze jejich pořadí. Jedná se sice o ztrátu určitého množství informace, nicméně i pořadí lze v biostatistikce využít.
- ➔ **Procento** (percentage) – sledujeme-li např. zlepšení v určitém parametru, je výhodné sledovat procentuální zlepšení. Př.: ejekční frakce levé srdeční komory.
- ➔ **Podíl** (ratio) – mnoho indexů je odvozeno jako podíl dvou měřených veličin. Př.: BMI.
- ➔ **Míra pravděpodobnosti** (rate) – týká se výskytu různých onemocnění, kdy počet nových pacientů v daném čase (studii) je vztažen na celkový počet zaznamenaných osoba-roků. Př.: výskyt nádorového onemocnění u pacientů ve studii.
- ➔ **Skóre** (score) – jedná se o uměle vytvořené hodnoty charakterizující určitý stav, který nelze jednoduše měřit jako číselné hodnoty. Př.: indexy kvality života.
- ➔ **Vizuální škála** (visual scale) – pacienti často hodnotí svoje obtíže na škále, která má formu úsečky o délce např. 10 cm. Př.: hodnocení kvality života.

Další typy dat – odvozená data

7 1 1 1 2 3 2 2 SUI.MYŠLENKY

10. Suicidální myšlenky

Život nestojí za to žít, myšlenky o vitanosti přirozené smrti, myšlenky na sebevraždu, příprava sebevraždy. Fakticky provedené suicidální pokusy neberte při skórování v úvahu

- 0 - má zájem na životě a nebo jej bere tak jak je
- 1 - potěšení ze života je oproti obvyklému stavu zdraví poněkud sníženo
- 2 - otrávený životem, občasně úvahy o suicidu
- 3 - připouští, že nebýt by bylo momentálně přijemnější než být, o suicidu jako řešení situace však neuvažuje
- 4 - raději by nežil, úvahy o suicidu časté, suicidium by bylo možným řešením situace, plány na suicidium však dosud nejsou konkrétní a promyšlené
- 5 - představa o způsobu suicidia je již konkrétní, konání však k tomu zatím nesměřovalo
- 6 - konkrétní plány na suicidium, kdyby byla možnost. Aktivní příprava suicidia


Absolutní vs. relativní četnost

- ➔ Vyjádření výsledků v relativní formě (procento) má často příjemnou interpretaci, ale může být zavádějící.
 - ➔ Relativní vyjádření účinnosti by mělo být vždy doprovázeno absolutním vyjádřením účinnosti.
- ➔ **Příklad:** Srovnání účinnosti léčiva ve smyslu prevence CMP u kardiáků.
- Studie 1: Výskyt CMP ve skupině A je 12 %, ve skupině B je 20 %.
Relativní změna v účinnosti = **40 %**; absolutní změna = **8 %**.
- Studie 2: výskyt CMP ve skupině A je 0,9 %, ve skupině B je 1,5 %.
Relativní změna v účinnosti = **40 %**; absolutní změna = **0,6 %**.
- ➔ Výsledkem je rozdílný přínos léčby při stejně relativní účinnosti.

Další typy dat – cenzorovaná data

- ➔ **Cenzorovaná data** charakterizují experimenty, kde sledujeme čas do výskytu předem definované události.
- ➔ V průběhu sledování událost nemusí nastat u všech subjektů. Subjekty však nelze vinit z toho, že jsme u nich nebyli schopni danou událost pozorovat a už vůbec je nelze z hodnocení vyloučit.
- ➔ O čase sledování takového subjektu pak mluvíme jako o **cenzorovaném**.
- ➔ Toto označení indikuje, že sledování bylo ukončeno dříve, než u subjektu došlo k definované události. Nevíme tedy, kdy a jestli vůbec daná událost u subjektu nastala, víme pouze, že nenastala před ukončením sledování.

Další typy dat – cenzorovaná data



3. Vizualizace a popis různých typů dat

Reálná data

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
ID_uniq	INICIALY	Věk	LEKAR	SEX	NHL_STUP	DG_1	DATUM_DG	IPI	LDH	B2M	KS	RT_OD	RT_DO	STAV	ZEMREL
1	MZ	59	Pytík	F	DLCL	DLCL	28.04.99	0	5.7	1.5	I			KR	
4	JS	64	Pytík	F	DLCL	DLCL	03.11.99	1	13.3	NA	II			ZTR	
6	VK	66	Pytík	F	difusní velkobuněčný B-lymfom	DLCL	19.01.00	2	11.1	2.5	III			EX	31.01.01
7	BK	41	Pytík	F	difusní lymfom z velkých bb	DLCL	27.04.00	0	8.3	2.3	I	12.09.00	13.10.00	KR	
8	ZV	74	Pytík	M	centroblastický B-lymfom	DLCL	13.11.00	3	12.6	2.6	III			KR	
11	DH	75	Pytík	M	DLCL	DLCL	15.03.01	0	7.1	3.0	II	25.06.01	18.07.01	KR	
12	JS	60	Jankovská	M	DLCL	DLCL	19.04.01	0	5.6	0.2	I			KR	
13	PF	26	Pytík	F	DLCL, bude 2. Čtení	DLCL	29.08.01	20	17.9	1.9	II			EX	07.09.02
14	JK	47	Jankovská	F	B-velkobuněčný	DLCL	17.10.01	0	8.6	2.1	III	xx.04.02		KR	
15	JJ	67	Jankovská	M	DLBCL	DLCL	07.02.02	0	8.4	5.6	I			KR	
16	HJ	73	Jankovská	F	DLCL	DLCL	15.02.02	0	6.5	1.4	II	27.05.02	14.06.02	KR	
17	VV	51	Jankovská	Ž	FCL/DLCL	DLCL	20.02.02	0	8.3	1.3	I			EX	18.05.02
22	FŘ	69	Jankovská	M	DLCL	DLCL	07.06.02	0	6.7	NA	I	22.08.03	20.09.03	PR	
23	OH	72	Jankovská	M	difusní velkobuněčný B lymfom	DLCL	25.10.02	1	8.2	2.5	III			KR	
24	JK	30	Jankovská	M	DLBCL	DLCL	31.01.03	1	13.8	1.8	II	plánovaná		KR	
25	EH	72	Jankovská	F	DLBCL	DLCL	06.08.03	2	9.2	1.7	III			KR	
26	MM	50	Jankovská	F	DLBCL	DLCL	05.09.03	1	7.3	1.7	III			KR	
32	MS	75	Kubáčková	F	DLCL	DLCL	03.03.99	1	8.8	1.5	I	20.07.99	16.08.99	KR	
33	RS	31	Kubáčková	M	DLCL	DLCL	17.08.00	1	8.8	2.0	I	27.02.01	26.03.01	KR	
34	JS	60	Kubáčková	M		DLCL	Motol	2	8	2.7	III			KR	
35	ZB	56	Kubáčková	M	DLCL	DLCL	19.02.01	1	9.8	2.4	II			KR	
36	JN	37	Kubáčková	M	DLCL	DLCL	13.03.01	1	16.1	2.0	I	24.10.01	21.11.01	KR	
37	AŠ	58	Kubáčková	F	difuzní B-lymfom, HG	DLCL	15.06.01	0	5.7	3.2	II	26.11.01	21.12.01	KR	
39	MH	56	Kubáčková	F		DLCL		1	11.4	2.0	I			EX	08.01.05
40	KŠ	83	Hrabětová	F	difusní velkobuněčný B lymfom	DLCL	01.07.02	2	32.0	6.0	I	28.01.03	10.02.03	EX	27.6.2003
41	LČ	53	Hrabětová	M		DLCL	Motol	0	5.2	1.9	I	21.1.2003	20.2.2003	KR	
48	MF	52	Kubáčková		DLBCL	DLCL	07.02.03	0	5.9	2.3	I			PR	
49	MČ	31	Kubáčková	F	DLBCL	DLCL		3	10.6	1.25	IV			KR	
50	VP		Papajík	M	DLBCL	DLCL	28.04.99	1	8.4	2.2	II			KR	15.11.02
51	AP		Papajík	M	DLBCL	DLCL	05.05.99	2	23.3	4.1	IV			EX	14.06.00
55															

Proč je popis a vizualizace dat třeba?


- ➔ Chceme **zpřehlednit** pozorovaná data – ve vhodných grafech.
- ➔ Chceme **zachytit** případné odlehlé a **extrémní** body nebo nečekané, **nelogické** hodnoty.
- ➔ Chceme **popsat** naměřené hodnoty.
- ➔ Chceme vypočítat vhodné sumární statistiky, které budou pozorovaná data dále **zastupovat** při prezentaci, srovnáních apod. Chceme pozorovanou informaci „uložit“ v zástupných statistikách, použití všech pozorovaných dat je nepraktické až nemožné.

Jaké jsou výstupy popisné analýzy?

- ➔ Obecně neformální, jde o **shrnutí pozorovaného** a ne o formální testování.
- ➔ **Vztahují se pouze na pozorovaná data** (respektive na experimentální vzorek).
- ➔ Mohou sloužit jako **podklad pro stanovení hypotéz**.

Co chceme u dat popsát?

- ➔ **Kvalitativní data** – četnosti (absolutní i relativní) jednotlivých kategorií.
- ➔ **Kvantitativní data** – těžiště a rozsah pozorovaných hodnot.



Popis „těžiště“ – míry polohy

- Mějme pozorované hodnoty: x_1, x_2, \dots, x_n
- Seřaďme je podle velikosti: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$

→ **Minimum a maximum** – nejmenší a největší pozorovaná hodnota nám dávají obraz o tom, kde se na ose x pohybujeme.

$$x_{\min} = x_{(1)}$$

$$x_{\max} = x_{(n)}$$

→ **Průměr** – charakterizuje hodnotu, kolem které kolísají ostatní pozorované hodnoty. Je to fyzikální obraz těžiště stejně hmotných bodů ose x.

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

→ **Medián** – je to prostřední pozorovaná hodnota. Dělí pozorované hodnoty na dvě půlky, půlka hodnot je menší a půlka hodnot je větší než medián.

$$\tilde{x} = x_{((n+1)/2)} \quad \text{pro } n \text{ liché}$$

$$\tilde{x} = \frac{1}{2}(x_{(n/2)} + x_{(n/2+1)}) \quad \text{pro } n \text{ sudé}$$

Výpočet mediánu

➔ Příklad 1: N = 8

$(n + 1) / 2$ pozice je „mezi“ 4. a 5. prvkem po seřazení – uděláme průměr

Data = 6 1 7 4 3 2 7 8

Seřazená data = 1 2 3 4 6 7 7 8

Medián = $(4 + 6) / 2 = 5$

➔ Příklad 2: N = 9

$(n + 1) / 2$ pozice znamená 5. pozice po seřazení


Data = 3,0 4,2 1,1 2,5 2,2 3,8 5,6 2,7 1,7

Seřazená data = 1,1 1,7 2,2 2,5 2,7 3,0 3,8 4,2 5,6

Medián = 2,7

Průměr vs. medián

- ➔ Máme-li symetrická data, je výsledek výpočtu průměru i mediánu podobný.
- ➔ Vše je OK.



Průměr vs. medián

- ➔ Nemáme-li symetrická data, je výsledek výpočtu průměru i mediánu rozdílný.
- ➔ Není to OK. Výpočet průměru je v tuto chvíli nevhodný!

➔ Příklad 1: známkování ve škole


- ➔ Student A: 1, 1, 1, 1, 2, 1, 1, 1, 1, 1, 1, 1, 1, 1, 5

Průměr = 1,35 Medián = 1,00

- ➔ Student B: 1, 1, 1, 1, 2, 1, 1, 1, 1, 1, 1, 1, 1, 1, 2

Průměr = 1,13 Medián = 1,00

➔ Příklad 2: plat v ČR v roce 2003



Pojem kvantil

- ➔ Ve statistice je **kvantil** definován pomocí kvantilové funkce, což je inverzní funkce k distribuční funkci – budeme se jí věnovat příště.
- ➔ Lze kvantil definovat jako číslo na reálné ose, které rozděluje pozorovaná data na dvě části: $p\%$ kvantil rozděluje data na $p\%$ hodnot a $(100-p)\%$ hodnot.


$$x_{p/100} = x_{(k)} \quad \text{pro } np/100 \text{ neceločíselné, pak } k = \lceil np/100 \rceil$$

$$x_{p/100} = \frac{1}{2}(x_{(k)} + x_{(k+1)}) \quad \text{pro } np/100 \text{ celočíselné, pak } k = np/100;$$



Kvantil - příklad

- ➔ Máme soubor 20 osob, u nichž měříme výšku. Chceme zjistit 80% kvantil souboru pozorovaných dat.



Významné kvantily

- ➔ Minimum = 0% kvantil
 - ➔ Dolní kvartil = 25% kvantil
 - ➔ **Medián = 50% kvantil**
 - ➔ Horní kvartil = 75% kvantil
 - ➔ Maximum = 100% kvantil
-
- ➔ **Medián** je významná charakteristika vypovídající o „těžišti“ pozorovaných hodnot. Není to ale jenom popisná charakteristika, na mediánu (a kvantilech obecně) je založeno mnoho **neparametrických statistických metod**.

Popis „rozsahu“ – míry variability


- ➔ Nejjednodušší charakteristikou variability pozorovaných dat je **rozsah hodnot** (rozpětí) = maximum – minimum. Je snadno ovlivnitelný netypickými (odlehlymi) hodnotami.
- ➔ **Kvantilové rozpětí** je definováno $p\%$ kvantilem a $(100-p)\%$ kvantilem a je méně ovlivněno odlehlymi hodnotami. Speciálním případem je **kvartilové rozpětí**, které pokrývá 50 % pozorovaných hodnot.
- ➔ **Výběrový rozptyl** – průměrný čtverec odchylky od průměru. Velmi ovlivnitelný odlehlymi hodnotami.

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

- ➔ **Výběrová směrodatná odchylka** – odmocnina z rozptylu. Výhodou směrodatné odchylky je, že má stejné jednotky jako pozorovaná data.

Popis „rozsahu“ – míry variability

- ➔ Příklad čtverců odchylek od průměru pro $n = 3$.
- ➔ Rozptyl je možno značně ovlivnit odlehlými pozorováními.



4. Kvalitativní data


Vizualizace a popis nominálních dat

- Vizualizace sloupcovým / koláčovým grafem – **absolutní i relativní četnost**.
- Sumarizace procentuálním výskytem kategorií v tzv. **frekvenční tabulce**.
- **Smysluplná agregace** kategorií zjednodušuje interpretaci i validitu výsledků.
- K popisu může sloužit i tzv. **modus** – nejčetnější pozorovaná hodnota.


Frekvenční tabulka

Proměnná	n	%
Kategorie 1	10	5.0
Kategorie 2	40	20.0
Kategorie 3	130	65.0
Kategorie 4	20	10.0
Celkem	200	100.0

Sloupcový graf



Koláčový graf




Vizualizace a popis ordinálních dat

- Vizualizace sloupcovým / koláčovým grafem – **absolutní i relativní četnost**.
- Sumarizace procentuálním výskytem kategorií v tzv. **frekvenční tabulce**.
- **Smysluplná agregace** kategorií zjednodušuje interpretaci i validitu výsledků.
- K popisu může sloužit i tzv. **modus**, případně **medián** (pouze dává-li to smysl).


Frekvenční tabulka

Proměnná	n	%
Kategorie 1	10	5.0
Kategorie 2	40	20.0
Kategorie 3	130	65.0
Kategorie 4	20	10.0
Celkem	200	100.0


Sloupcový graf



Koláčový graf




Co je na tom obrázku zavádějící?



A significantly higher proportion of patients in the appendicectomy group than in the inspection-only group had an improvement in pain (14 of 18 *versus* seven of 22; $P = 0.005$). The relative risk was 2.4 (95 per cent c.i. 1.3 to 4.0), indicating that patients who had an appendicec-

Fig. 2 Distribution of pain scores in patients whose appendix was removed during laparoscopy and those in whom it was left *in situ*

Co je na tom obrázku zavádějící?



A significantly higher proportion of patients in the appendectomy group than in the inspection-only group had an improvement in pain (14 of 18 *versus* seven of 22; $P = 0.005$). The relative risk was 2.4 (95 per cent c.i. 1.3 to 4.0), indicating that patients who had an appendice-

➔ Ve chvíli, kdy obě skupiny mají různý počet pacientů, je srovnání absolutních čísel nekorektní.

Fig. 2 Distribution of pain scores in patients whose appendix was removed during laparoscopy and those in whom it was left *in situ*

5. Kvantitativní data

Frekvenční tabulka pro kvantitativní data

Primární data

1,21
1,48
1,56
0,31
1,21
1,33
0,33
0,21
1,32
1,11
.
.
.
.

$n = 100$



Frekvenční tabulka

- ➔ d_i – šířka intervalu
- ➔ n_i – absolutní četnost v daném intervalu
- ➔ n_i / n – relativní četnost v daném intervalu

i -tý interval	d_i	n_i	n_i / n	%
$<0 - 0,4)$	0,4	20	0,2	20
$<0,4 - 0,8)$	0,4	10	0,1	10
$<0,8 - 1,2)$	0,4	40	0,4	40
$<1,2 - 1,4)$	0,2	20	0,2	20
$<1,4 - 1,6)$	0,2	10	0,1	10
Celkem	1,6	100	1	100

Histogram

- Histogram je grafický nástroj pro vizualizaci **kvantitativních dat** (poměrových, intervalových, spojitých i diskrétních).
- Každá oblast histogramu odráží **absolutní nebo relativní četnost na jednotku sledované proměnné na ose x.**
- Histogram není sloupcový graf!


- Histogram pro relativní četnost:
$$f(i) = \frac{n_i / n}{d_i}$$
- Histogram pro absolutní četnost:
$$f(i) = \frac{n_i}{d_i}$$

Sumarizace kvantitativních dat histogramem


- ➔ Pozorovaná data: 1,21; 1,48; 1,56; 0,31; 1,21; 1,33; 0,33; 0,21; 1,32 n
- ➔ Setřídění dat podle velikosti
- ➔ Vytvoření intervalů na ose x
- ➔ Výpočet relativních nebo absolutních četností $f(i)$
- ➔ Vykreslení histogramu

Histogram – příklad

Histogram pro absolutní četnost



Histogram pro relativní četnost




Histogram – příklad

➔ Jaký obsah má plocha histogramu pro relativní četnost?

➔ A proč?

Histogram pro relativní četnost




Histogram – příklad

- ➔ Jaký obsah má plocha histogramu pro relativní četnost?

$$\sum_i f(i) = \sum_i \frac{n_i / n}{d_i} = 1$$



- ➔ A proč?
- ➔ Histogram lze použít pro odhad hustoty pravděpodobnosti. Je to tedy grafická vizualizace rozložení pravděpodobnosti kvantitativních (zejména spojitéhých) dat.

Histogram pro relativní četnost



Který histogram je správný a proč?

- ➔ Chceme pomocí histogramu vykreslit počty zraněných při automobilových haváriích na předměstí Londýna v roce 1985. Data máme zadána jako počty v daných věkových kategoriích.



Histogram ve skutečnosti

- Histogram je ve skutečnosti zřídka vyjadřován pomocí výrazů:

$$f(i) = \frac{n_i / n}{d_i} \quad f(i) = \frac{n_i}{d_i}$$




- Daleko častěji se jedná o prosté absolutní nebo relativní počty pozorování v daném intervalu (výhodné kvůli snadné čitelnosti a interpretaci):

$$f(i) = n_i / n \quad f(i) = n_i$$


- Důležité však je, aby intervaly měly stejnou šířku, aby výsledky byly srovnatelné!

Počet intervalů určuje kvalitu výstupu

➔ Počtem zvolených intervalů v histogramu rozhodujeme o tom, jak bude vypadat. Při malém počtu můžeme přehlédnout důležité prvky v datech, při velkém zase může být informace roztríštěná.



Krabicový graf – box plot



Co je extrémní (odlehlá) hodnota?

- ➔ Jednoduše řečeno se jedná o netypické pozorování, které nezypadá do pravděpodobnostního chování souboru dat.
- ➔ Definujeme ji jako hodnotu, která leží několikanásobek (3, 5, 7) směrodatné odchylky , respektive kvartilového rozpětí, od průměru, respektive mediánu.
- ➔ Definice je ale vágní, závisí na naší znalosti dané problematiky, které hodnoty jsou či nejsou možné!

Vliv odlehlé hodnoty na popisné statistiky

Cílem je určit průměrnou hladinu cholesterolu vybrané populace mužů
(hodnoty v mmol/l)

Správná data

6.3
7.6
6.3
9.1
4.2
5.8
5.65
6.3
8.6
6
6.2
6.7
4.6
6.25
6.3
4.04
6.3
9.1
6.3
5.2
6.4
5.75

Průměrná hodnota
6,32

Směrodatná odchylka
1,34


Nesprávná data

6.3
7.6
6.3
9.1
4.2
5.8
5.65
6.3
8.6
6
6.2
6.7
4.6
6.25
6.3
4.04
6.3
9.1
6.3
5.2
64
5.75

Která charakteristika se zvýší výrazněji?
Průměr nebo směrodatná odchylka?

Vliv odlehlé hodnoty na popisné statistiky

Cílem je určit průměrnou hladinu cholesterolu vybrané populace mužů
(hodnoty v mmol/l)



Identifikace odlehlých hodnot

- ➔ Na menších souborech stačí vizualizace.
- ➔ Na větších datových souborech nelze bez vizualizace a popisných statistik.


- ➔ Grafická identifikace: pomocí histogramu a box plotu.
- ➔ Identifikace pomocí popisných statistik: srovnání mediánu a průměru.

Identifikace odlehlých hodnot – příklad


Správná data

6.3
7.6
6.3
9.1
4.2
5.8
5.65
6.3
8.6
6
6.2
6.7
4.6
6.25
6.3
4.04
6.3
9.1
6.3
5.2
6.4
5.75


Histogram




Box plot



Histogram



Box plot




Nesprávná data

6.3
7.6
6.3
9.1
4.2
5.8
5.65
6.3
8.6
6
6.2
6.7
4.6
6.25
6.3
4.04
6.3
9.1
6.3
5.2
64
5.75


Identifikace odlehlých hodnot – příklad

Cílem je určit průměrnou hladinu cholesterolu vybrané populace mužů
(hodnoty v mmol/l)



Reklama na příští týden...

Středem zájmu statistiky a biostatistiky je tzv. náhodná veličina.



Poděkování...

Rozvoj studijního oboru „Matematická biologie“ PřF MU Brno je finančně podporován prostředky projektu ESF č. CZ.1.07/2.2.00/07.0318 „Víceoborová inovace studia Matematické biologie“ a státním rozpočtem České republiky



evropský
sociální
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenceschopnost



UNIVERSITAS
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tomáš Pavlík



Biostatistika