

PSY117 2016

Statistická analýza dat v psychologii

Přednáška 1

---

# ÚVOD, ČETNOSTI A ROZLOŽENÍ ČETNOSTÍ

Je snadné lhát s pomocí statistiky.

Je těžké říkat pravdu bezní.

*Andrejs Dunkels; wikiquote*



is it normal

is it normal to talk to yourself

is it normal for your period to be brown

is it normal to miss a period

is it normal to be sexually attracted to numbers

is it normal to bleed during intercourse

is it normal to get your period late

is it normal to poop green

is it normal to have headaches everyday

is it normal to have hair on your bum

is it normal to spot during pregnancy

FAIL

Google Search

I'm Feeling Lucky

# Kostra PSY117 – Statistická analýza dat

---

- Pochopení základních statistických pojmů
  - Použití základních statistických postupů
  - Aktivní i pasivní komunikace statistických zjištění
- 
- 2 seminární práce (20b)
  - 3 průběžné písemky (3x10b)
  - Závěrečný test (50b)
-

# Obtížnost statistiky

---

Kód	Zapsáno	A	B	C	D	E	F	-
2015	78	7	10	19	18	7	6	9
2014	73	4	6	20	13	11	10	8
2013	98	6	18	16	15	9	16	14
2012	84	8	25	8	12	4	16	9
2011	76	9	11	12	11	4	12	15
2010	81	8	17	12	13	8	11	9

---



# Obtížnost statistiky

---

Kód	Zapsáno	A	B	C	D	E	F	-
2015	78	9%	13%	24%	23%	9%	8%	12%
2014	73	5%	8%	27%	18%	15%	14%	11%
2013	98	6%	18%	16%	15%	9%	16%	14%
2012	84	10%	30%	10%	14%	5%	19%	11%
2011	76	12%	14%	16%	14%	5%	16%	20%
2010	81	10%	21%	15%	16%	10%	14%	11%

# Obtížnost statistiky

- Statistika je obtížná ... i pro přírodovědně orientované
- Matematické dovednosti kamenem úrazu nejsou, většinou je máte ( $r_s=0,13$ )
- Statistika koreluje s ostatními Áčky – společným jmenovatelem je snaha a obecné předpoklady.



101	102	103	104	105	106	107	108	112	113	118	
$r_s$	0,36	0,53	0,52	0,59	0,51	0,53	0,56	0,49	0,42	0,33	0,36

# Jak se učit statistiku

---

- S. = lehká matematika, těžké myšlení
- ...jako cizí jazyk
  - po malých kouscích, pravidelně
  - pozor na slovíčka
  - prakticky: tužka-papír-kalkulačka + počítač (Excel, SPSS, Statistica...)
- Neexistuje dobrá učebnice v češtině
  - Hendl – i ve čtvrtém vydání žádná cvičení, obtížně stravitelný text
  - zbývá angličtina: např. **Howell**; Howitt&Cramer; Glass&Hopkins, Field
  - web: wiki, statsoft.com
- ...sám i společně
  - diskuzní fórum FB: <http://goo.gl/Mt95eT>
  - poskytovna: sdílení materiálů



KEEP  
CALM  
AND  
STUDY  
STATISTICS

# Co je to vlastně statistika?

---

- **Popis** získaných **dat** o **jevech**, které se vyskytují ve větších množstvích
  - Popis **proměnných**: jaké podoby jevu, jak časté?
  - Popis **vztahů** mezi proměnnými/jevy
  
- Statistické **usuzování** ze vzorku na populaci
  - Pravděpodobnostní usuzování
  - Konfrontace očekávání (modelů) se získanými daty
  - Testování hypotéz

# K čemu je statistika jako taková?

---

- Formalizované **zpracování zkušenosti**, když
    - počet zkušeností, výskytů jevu přesáhne  $7 \pm 2$  (automat)
    - hledané je malé (mikroskop)
    - záludnosti naší kognice představují problém (zvl. paměť)
  - Motivuje vytváření záznamů o zkušenosti (a.k.a. dat)
  - „Objektivní“ (=v komunitě srozumitelný) popis výskytu jevů
  - Hledání společného, typického, normálního i jedinečného
  - Hledání vztahů, souvislostí mezi jevy
  - Trénuje myšlení
    - kritické myšlení, modely vzniku jevů
    - myšlení o variabilitě jevů ( $\approx$  rozdílech mezi lidmi>)
    - uvědomění si všudypřítomnosti chyby měření (vnímání)
    - **pravděpodobnostní myšlení**
-

# K čemu je statistika psychologům?

---

1. V běžném životě – statistická gramotnost (literacy)
  2. Ve výzkumu
    - hledání pravidelností + identifikace jedinců, kteří se těmto pravidelnostem vzdalují
  3. V aplikovaných disciplínách a praxi
    - formalizovaná reflexe praxe - zjišťování efektů, výsledků – co se mi osvědčuje a co ne?
  4. Při diagnostice, poznávání lidí
    - diagnostické metody mají statistické základy
    - statistické pojetí normality a odchylky od ní
    - pravděpodobnost správného určení diagnózy
-

# Malá mapa semestru

---

- Jaké hodnoty(podoby jevu) se vyskytují a jak často?
    - Je v tom nějaká pravidelnost?
  - Existuje souvislost mezi výskytem jednoho jevu a výskytem nějakého jiného?
    - Dokážeme z existence jednoho jevu usuzovat na ten druhý?
  - Jak velké zkreslení asi vzniklo tím, že máme data jen o zlomku všech výskytů zkoumaného jevu?
-

12,08	1	2	2	15	11	5	1
12,58	1	1	1	24	13	4	1
11,92	1	2	2	7	13	6	2
12,33	1	2	2	10	17	4	2
12,08	1	1	1	7	13	6	1
11,92	1	2	2	10	11	4	1
12,67	1	2	1	16	11	3	1
12,08	1	2	2	7	1	6	1
12,25	1	1	1	24	11	4	1
12,67	1	1	2	6	1	6	1
12,08	1	2	2	7	10	4	2
12,67	1	1	2	10	17	6	1

# Data, proměnné

---

- Data vznikají měřením(záznamem) jevů
- Data mají obvykle podobu proměnných
  - Proměnné vznikají(jsou) **kódováním dat**
  - Z jedněch dat můžeme udělat více proměnných
- Proměnné reprezentují *znaky, charakteristiky, atributy, vlastnosti* zkoumaných jevů či objektů, popř. jejich kombinace
- Proměnné nabývají různých hodnot, pokud ne, jsou to **konstanty**

# Data, proměnné

---

- Data vznikají měřením(záznamem) jevů

Měření: Standardizovaný postup, procedura

**Procedura, kt. dává číslům smysl**

Tato procedura je **vždy** zatížena chybou

Někdy je měření prostý **záznam**

# Data, proměnné

---

- Data vznikají měřením(záznamem) jevů
- Data mají obvykle podobu proměnných
  - Proměnné vznikají(jsou) **kódováním dat**
  - Z jedněch dat můžeme udělat více proměnných
- Proměnné reprezentují *znaky, charakteristiky, atributy, vlastnosti* zkoumaných jevů či objektů, popř. jejich kombinace
- Proměnné nabývají různých hodnot, pokud ne, jsou to **konstanty**

věk	národnost	mat	cj	pr_oblib	pr_neobl	ocek_vzd	stav_r
12,08	1	2	2	15	11	5	1
12,58	1	1	1	24	13	4	1
11,92	1	2	2	7	13	6	2
12,33	1	2	2	10	17	4	2
12,08	1	1	1	7	13	6	1
11,92	1	2	2	10	11	4	1
12,67	1	2	1	16	11	3	1
12,08	1	2	2	7	1	6	1
12,25	1	1	1	24	11	4	1
12,67	1	1	2	6	1	6	1
12,08	1	2	2	7	10	4	2
12,67	1	1	2	10	17	6	1

# Co ta čísla-kódy znamenají?

## Úrovně měření (typy měřítka, škály)

<b>Úroveň</b>	<b>Operace</b>	<b>Příklady</b>
<b>1</b> Nominální	= ≠	pohlaví, tramvaj, preference
<b>2</b> Ordinální (pořadová)	= ≠ > <	známky, souhlasení
<b>3</b> Intervalová	= ≠ > < + -	°C, IQ, „dobré“ psychotesty
<b>4</b> Poměrová	= ≠ > < + - × ÷	K, váha, počty, frekvence

1+2: kategorické, 3+4: metrické, kardinální;

Howitt&Cramer: nominal category data (1) vs score data (2-4)

Více viz extrakt z Urbánek, Denglerová, Širůček v ISu

# Typy proměnných podle počtu možných hodnot


---

- **Spojité** proměnné
  - Nekonečně mnoho hodnot – reálná čísla
- **Diskrétní** proměnné
  - [Nekonečně] mnoho hodnot, jen některá (typicky celá) čísla – často se k nim chováme jako ke spojitým
  - Nemnoho hodnot
    - jen 2 možné hodnoty: **dichotomické** (alternativní)
    - „pár“ možných hodnot: **polytomické**

# Zacházení s proměnnými podle jejich typu

---

- Reálné proměnné na ideální typy často přesně nepasují
- Rozlišujeme měřenou charakteristiku a škálu, pomocí které byla změřena
  - Často je v psychologii charakteristika uvažována jako intervalová spojitá proměnná, kterou měříme diskrétní polytomickou škálou
  - Př. Postoj
- Hledáme argumenty pro to, abychom mohli škálu považovat za intervalovou – jednodušší statistiky, více informace, riziko zkreslení.
  - Flexibilní, argumentující, opatrný přístup – žádné dogma.



Created by Brendan Powell Smith: [www.TheBrickTestament.com](http://www.TheBrickTestament.com). This chart is not sponsored, authorized, or endorsed by the LEGO Group.

# Shrnutí

---

- Při hledání odpovědí na otázky a řešení problémů je užitečné využít data – psychologie jako empirická věda
  - I při reflexi vlastních zkušeností je užitečné nespolehat jen na paměť
  - Každá statistika má smysl jen jako podklad pro odpověď na určitou otázku – ne sama o sobě – a v kontextu této otázky má smysl ji i komunikovat
  - Tyto principy jsou užitečné stejně občanovi jako psychologovi i jako výzkumníkovi v psychologii
  - Data tvoříme (my nebo někdo jiný) a tomu, co potřebujeme vědět, odpovídají vždy nedokonale
  - Tvoříme různé typy dat, pro které máme různé statistiky – kategorie vs. škály
-

# Máme data

---

„účetnictví“ může začít

# Jaké hodnoty máme v datech?

---

- Jaké hodnoty proměnné/ých se v datech vyskytují? – *třídění, kódování*
    - Jaké různé odpovědi jsme získali na tu kterou otázku dotazníku?
    - Jaké různé počty sledovaných chování se při pozorování vyskytly?
  - Kolik kterých hodnot máme? – *četnosti*
    - Je některých víc, jiných míň?
    - Zdá se být v četnostech jednotlivých hodnot nějaký řád?
-

# Tabulka četností (frekvencí)

<b>hodnota/ interval</b>	<b>(absolutní) četnost</b>		<b>relativní četn. (%)</b>	<b>kumulativní rel. č.</b>
Minimum / interval1				
Hodnota2 / interval2				
...				
Maximum / posl. interv.				100
Celkem	<b>N</b>		100	

?: „počet“ v Tab 3.2, hustota (jde o hustotu pravděpodobnosti), obr. 3.5 – ne frekvence, ale procenta

AJ: (absolute) frequencies, relative frequencies, percent, cumulative, value, interval (class), total, N=sample size

V Excelu funkce ČETNOSTI. Zadává se zrádně: vybrat buňky, které mají obsahovat absolutní četnosti; napsat funkci a !!ukončit Ctrl+Shift+Enter.

# Tabulka četností - poznámky

---

- Od nejmenší hodnoty po nejvyšší
  - v 1. a 2. sl. obvykle zahrnutý chybějící hodnoty
    - Pak se rozlišuje mezi platnými hodnotami a chybějícími hodnotami
  - hodnoty – kategorické proměnné, málo hodnot u metrické
  - intervaly(třídy) – metrické proměnné
    - volba šířky intervalu (stojí za to vyzkoušet více)
      - aby byl jejich počet přibližně  $N/10$ ,  $<15$ , nebo  $1+\log_2 N$  (Sturgisovo pravidlo)
      - stejná šířka všech intervalů
  - Tabulka četností zobrazuje téměř všechna data
    - Použitím intervalů již data mírně redukujeme
  - Minimální podoba tabulky četností: **absolutní a relativní četnosti, součtový poslední řádek**
-

Věk	Interval		Četnost	kumulativní četnost	relativní četnost %	relativní četnost cum %	kumulativní četnost cum %
	Dolní mez	Horní mez					
2							
3			$n_i$	$N_i$	$f_i$	$F_i$	
5	0	20	8	8	40		40
5	21	40	1	9	5		45
7	41	60	4	13	20		65
16	61	80	5	18	25		90
17	81	100	2	20	10		100
19	Celkem		20		100		


Též Datíčka.xls, list „četnosti“.

# Grafické podoby tabulky četností


---

- Kategorické proměnné
  - sloupcový graf (diagram)
  - koláčový diagram – zřídka kdy, neukazuje rozložení
- Metrické proměnné
  - Histogram – jako sloupcový, ale šíře sloupců reprezentuje šíři intervalů
  - stem-and-leaf – rozdělení hodnot do intervalů


# Sloupcový diagram




# Sloupcový diagram s tříděním




?






**Přibližně kolik hodin týdně strávíte sportováním?**



**Přibližně kolik hodin týdně strávíte sportováním?**

# Kumulativní histogram



# Číslicový histogram „stonek a list“




Frequency	Stem &	Leaf
32, 00	0 .	00000000
18, 00	1 .	00000000
14, 00	2 .	00000000
7, 00	3 .	0000000
2, 00	4 .	00
4, 00	5 .	0000
1, 00	6 .	0
1, 00	7 .	0
10, 00	Extremes	(>=8, 0)

Stem width: 1  
Each leaf: 1 case(s)

# „Férové“ zobrazení dat



---

- Každý graf (i tabulka) musí být natolik přehledně popsán (nadpis + popisky uvnitř), aby byl srozumitelný i bez čtení textu
  - Rozličné rady, např. Good, Hardin
    - Popisky dat by neměly stínit datové body
    - Rozsah škál by měl být volen smysluplně, aby byla plocha užitečně využita („nulové“ body na škálách).
    - Numerické osy naznačují spojité proměnné, u kategorií volme raději textové popisky.
    - Nepropojujme datové body, jde-li o diskrétní škály, pokud nemá interpolace smysl, nebo pokud nemáme v úmyslu srovnání profilů
  - Další
    - Hans Rosling na TEDu: [http://www.ted.com/talks/hans\\_rosling\\_shows\\_the\\_best\\_stats\\_you\\_ve\\_ever\\_seen.html](http://www.ted.com/talks/hans_rosling_shows_the_best_stats_you_ve_ever_seen.html)
    - Nathan Yau: Visualise this... <http://www.amazon.com/o/ASIN/0470944889>tag=adapas02-20>
    - **Howitt & Cramer s. 21**
-



# Rozložení rozdělení, distribuce četností


- Měřené jevy jsou nějak rozděleny do kategorií (intervalů) a tyto kategorie jsou různě „populární“ – četné.
- Četnosti u reálných ordinálních a vyšších proměnných obvykle nebývají **distribuovány** nahodile – jejich rozdělení zobrazené histogramem má popsatelný tvar.



- **Rozdělení** četností je tedy to, kolik relativně (či absolutně) máme kterých hodnot měřené proměnné.
  - Typicky lze přibližně popsát slovy, např.: vyskytlo se hodně středních hodnot a relativně málo extrémních hodnot.
  - Toto **rozložení** jevů na měřené škále je nejlépe vidět na grafech.
  - Obvykle nějaké konkrétní rozložení očekáváme.


# Tvar rozložení četnosti

- Normální
- Uniformní
- Počet vrcholů
  - Unimodální, bimodální, multimodální
- Zešikmení
  - Zešikmené zprava (pozitivně), efekt podlahy
  - Zešikmené zleva (negativně), efekt stropu
- Strmost
  - Leptokurtické, platykurtické



AJ: frequency distribution, normal, rectangular, unimodal, bimodal, positively/negatively skewed, lepto(platy)kurtic, floor/ceiling effect


# Normální (Gaussovo) rozložení



- „Normální“ ve smyslu „velmi běžné“
- Tam, kde se setkává mnoho nezávislých vlivů.
- Ne vždy, nesouvisí s „kvalitou“ dat.

AJ: normal distribution, bell curve

# Poissonovo rozložení



- Rozložení četnosti výskytu řídkých událostí (ta lambda v grafu = průměrná frekvence za jednotku času)
- Děje-li se událost v průměru častěji, než 10x za časovou jednotku, která nás zajímá, je jeho dobrou approximací normální rozložení.

# Rozložení

---

- Známky ze statistiky
  - Výška studentů psychologie
  - Depresivita
  - Postoje k interrupcím
  - Spokojenost se studiem
  - Pohlaví na psychologii
  - Počet návštěv u lékaře
-

# Shrnutí

---

- První informací (*statistikou*), která nás zajímá je **četnost** výskytu jednotlivých hodnot (resp. hodnot uvnitř jednotlivých intervalů)
  - Konfiguraci **četností** nazýváme **rozložení (rozdělení)**.
  - Rozložení popisujeme (=komunikujeme je)
    - tabulkou četností
    - graficky – histogram, sloupcový diagram
    - (pomocí percentilů)
  - O typu, tvaru **rozložení** hodnot proměnné uvažujeme většinou graficky – **histogram, sloupcový diagram**.
  - Nejčastěji diskutovaným rozložením je tzv. **normální rozložení**.
-