

# ASTAc/03 Biostatistika

## 2. cvičení



Kontingenční tabulky v Excelu

Základní popisné statistiky

Představení programu Statistica

Import a základní popis dat ve Statistice

# I. Kontingenční tabulky v Excelu



# Kontingenční tabulka



- Frekvenční summarizace dvou kategoriálních proměnných (binárních, nominálních nebo ordinálních proměnných).
- Obecně: **R x C kontingenční tabulka** (R – počet kategorií jedné proměnné, C – počet kategorií druhé proměnné).
- Speciální případ: 2 x 2 tabulka = čtyřpolní tabulka.
- Kontingenční tabulky: **absolutních četností, celkových procent, řádkových/sloupcových četností**
- Př.: Sumarizace vyšetřených osob podle pohlaví a výsledku diagnostického testu.

Pohlaví	Výsledek vyšetření		Celkem
	Nemocný	Zdravý	
Muž	45	11	56
Žena	25	6	31
Celkem	70	17	87

# Ukázka kontingenční tabulky

- Vztah pohlaví a výskytu onemocnění (pozor na hodnocení nesmyslného vztahu)

	Nemocný	Zdravý	Celkem
Muž	a	b	$a + b$
Žena	c	d	$c + d$
Celkem	$a + c$	$b + d$	$a + b + c + d = N$

↓

Marginální absolutní četnost

Celkový počet hodnot

Simultánní absolutní četnost

	Nemocný	Zdravý	Celkem
Muž	45	11	56
Žena	25	6	31
Celkem	70	17	87




Jsou více nemocní muži nebo ženy?

# Ukázka kontingenční tabulky

	Nemocný	Zdravý	Celkem
Muž	45	11	56
Žena	25	6	31
Celkem	70	17	87

Kontingenční tabulka  
absolutních četností



Větší počet nemocných mužů, který je dán pouze vyšším zastoupení mužů v celkovém vzorku (56 z 87)

	Nemocný	Zdravý	Celkem
Muž	80,4 %	19,6 %	100,0 %
Žena	80,6 %	19,4 %	100,0 %

Kontingenční tabulka  
řádkových procent



Po výpočtu relativních četností vidíme, že se muži a ženy neliší ve výskytu onemocnění



Jsou více nemocní muži nebo ženy?

# Kontingenční tabulky v Excelu: zdroj dat a příprava dat



**Kontingenční tabulka se dá vytvořit:**


1. z tabulky v daném sešitě
2. z dat z jiného sešitu Excelu
3. z externích dat (např. MS Access)
4. ze sloučených dat z více oblastí - z různých listů nebo různých sešitů
5. z jiné kontingenční tabulky

**Data musí být uspořádána formou standardního databázového seznamu:**

- V prvním řádku: názvy polí
- Další řádky: data

Vzhled tabulky: karta Domů → Formátovat jako tabulku

# Vytvoření kontingenční tabulky v Excelu



# Kontingenční tabulky – rozvržení

The screenshot shows the Microsoft Excel ribbon at the top with tabs like Home, Insert, Page Layout, Formulas, Data, etc. Below the ribbon is a worksheet titled "List1". In cell A3, there is a button labeled "Kontingenční tabulka 1". To the right of the button, a text box says: "Chcete-li vytvořit sestavu, zvolte pole ze seznamu polí kontingenční tabulky." Below this text is a diagram of a 2x2 grid with arrows indicating data flow between rows and columns.

On the right side of the screen, the "Seznam polí kontingenční tabulky" (List of fields for contingency table) dialog box is open. It contains a list of variables: age, agecat, gender, diabetes, bp, smoker, choles, active, obesity, angina, mi, nitro, and antidipt. A red arrow points from the text "parametry na řádcích" (parameters on rows) to the "Popisky řádků" (Row labels) section of the dialog. Another red arrow points from the text "parametry dat" (data parameters) to the "Σ Hodnoty" (Sum of values) section. A third red arrow points from the text "parametry ve sloupcích" (parameters in columns) to the "Popisky sloupců" (Column labels) section. A fourth red arrow points from the text "parametry, které je možné zobrazit v kontingenční tabulce" (parameters that can be displayed in a contingency table) to the "Zvolte pole, které chcete přidat do sestavy:" (Select the field you want to add to the composition) list.

At the bottom of the dialog, there is a "Filtr" (Filter) button and a "Odložit aktualizaci rozložení" (Delay update of distribution) checkbox. There is also an "Aktualizovat" (Update) button.

To the right of the main dialog, a preview window shows the resulting pivot table setup. It includes sections for "Filtr sestavy" (Composition filter), "Popisky sloupců" (Column labels), "Popisky řádků" (Row labels), and "Σ Hodnoty" (Sum of values). The "smoker" variable is selected in the column labels, and "agecat" is selected in the row labels. The preview also shows "Popisky řádků" and "Σ Hodnoty" for the "agecat" variable.

# Kontingenční tabulky – nastavení II.

Kontingenční tabulka

Popisy řádků	No	Yes	Celkový součet
45-54	1694	501	2195
55-64	3015	863	3878
65-74	2200	661	2861
75+	816	250	1066
<b>Celkový součet</b>	<b>7725</b>	<b>2275</b>	<b>10000</b>

Seznam polí kontingenční tabulky

Zvolte pole, které chcete přidat do sestavy:

- age
- agecat**
- gender
- diabetes
- bp
- smoker**
- choles

Přesunout nahoru

Přesunout dolů

Přesunout na začátek

Přesunout na konec

Přejít k filtrovi sestavy

Přejít k popiskům řádků

Přejít k popiskům sloupců

Přejít k hodnotám

Odstranit pole

Nastavení polí hodnot...

Počet z agecat

Nastavení polí hodnot

Název zdroje: agecat

Vlastní název: Počet z agecat

Souhrn Zobrazit hodnoty jako

Kritéria shrnutí pole hodnoty

Zvolte typ kalkulace, který chcete použít pro shrnutí dat z vybraného pole:

- Součet
- Počet**
- Průměr
- Maximum
- Minimum
- Součin

Způsob summarizace položky

Popisy řádků	No	Yes	Celkový součet
45-54	1694	501	2195
55-64	3015	863	3878
65-74	2200	661	2861
75+	816	250	1066
<b>Celkový součet</b>	<b>7725</b>	<b>2275</b>	<b>10000</b>

# Aktualizace dat v kontingenční tabulce




Při změně dat v tabulce se zdrojovými daty **nedoje** automaticky k aktualizaci dat v kontingenční tabulce.

**Musíte provést aktualizaci dat.**

1. Stůjte kdekoliv v kontingenční tabulce
2. Na kartě **Možnosti** ve skupině **Data** klikněte na **Aktualizovat** (Alt+F5), nebo na **Aktualizovat vše** (Ctrl+Alt+F5)

Data z kontingenční tabulky lze vizualizovat pomocí **kontingenčního grafu**



# Rozložení kontingenční tabulky

---



Po vytvoření se kontingenční tabulka zobrazí v tzv. **kompaktním formátu**. Lze ji zobrazit ale i ve formě **tabulky**, nebo ve formě **osnovy**.

1. Stůjte kdekoliv v kontingenční tabulce
2. Na kartě **Návrh** vyberte tlačítko **Rozložení sestavy** a volbu **Zobrazit ve formě osnovy nebo zobrazit ve formě tabulky**

**Kompaktní formát** - uspořádání tabulky aby zabírala co nejméně místa

**Forma osnovy** - řádková pole nižší úrovně je od vyšších úrovní odsazena, řádky nejsou odděleny čarami

**Forma tabulky** - klasická forma tabulky, pole nižší úrovně jsou v dalším sloupci

**Vyzkoušej!**

# II. Základy popisné statistiky



# Jaké úlohy řeší biostatistika?

---



- **Popis cílové populace** – odhady charakteristik cílové populace
- **Srovnání skupin** – testování hypotéz
- **Regresní analýza** – stochastické modelování pro vysvětlení variability
- **Predikce a klasifikace** – stochastické modelování a klasifikační algoritmy pro předpovídání neznámých hodnot

# Motivace

---



- 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.

# Typy proměnných



## Kvalitativní (kategoriální) proměnná

- lze ji řadit do kategorií, ale nelze ji kvantifikovat

*Příklad: ??*

## Kvantitativní (numerická) proměnná

- můžeme ji přiřadit číselnou hodnotu

*Příklad: ??*

# Typy proměnných

---



## Kvalitativní (kategoriální) proměnná

- lze ji řadit do kategorií, ale nelze ji kvantifikovat
- Příklady: *pohlaví, HIV status, barva vlasů ...*

## Kvantitativní (numerická) proměnná

- můžeme ji přiřadit číselnou hodnotu
- Příklady: *výška, váha, teplota, počet hospitalizací ...*

# Kvalitativní znaky



- **Binární znaky**: dvě kategorie, obvykle se kódují pomocí číslic 1 (přítomnost sledovaného znaku) a 0 (nepřítomnost sledovaného znaku).

*Příklad: ??*

- **Nominální znaky**: několik kategorií (A, B, C), které nelze uspořádat.

*Příklad: ??*

- **Ordinální znaky**: několik kategorií, které lze vzájemně seřadit, tedy můžeme se ptát, která je větší/menší ( $1 < 2 < 3$ ).

*Příklad: ??*

# Kvalitativní znaky

---



- **Binární znaky**: dvě kategorie, obvykle se kódují pomocí číslic 1 (přítomnost sledovaného znaku) a 0 (nepřítomnost sledovaného znaku).

*Příklady: Diabetes (1-ano, 0-ne), Pohlaví (1-muž, 0-žena).*

- **Nominální znaky**: několik kategorií (A, B, C), které nelze uspořádat.

*Příklad: krevní skupiny (A/B/AB/O).*

- **Ordinální znaky**: několik kategorií, které lze vzájemně seřadit, tedy můžeme se ptát, která je větší/menší (1<2<3).

*Příklady: stupeň bolesti (mírná/střední/velká), stadium maligního onemocnění (I/II/III/IV).*

# Kvantitativní znaky



- **Intervalové znaky:** interpretace rozdílu dvou hodnot (stejný interval mezi jednou a druhou dvojicí hodnot vyjadřuje i stejný rozdíl v intenzitě zkoumané vlastnosti). Společný znak intervalových znaků: nula byla stanovena uměle, tedy pouhou konvencí. *Příklad: teplota měřená ve stupních Celsia, letopočet.*

Den	Teplota	Rozdíl <sup>1</sup>	Podíl <sup>1</sup>
1.	2 °C	-	-
2.	4 °C	+2	2x
3.	6 °C	+2	1.5x


<sup>1</sup> Srovnání s měřením z předchozího dne

1.5krát vyšší teplota ve srovnání s 2.

← dnem, přičemž došlo ke stejnemu nárůstu teploty jako při srovnání 2. a 1. dne

- **Poměrové znaky:** kromě rozdílu interpretujeme i podíl dvou hodnot.  
*Příklady: výška v cm, váha v kg, ...*

# Různé typy dat znamenají různou informaci



# Jak vznikají informace ?

## - frekvenční tabulka jako základní nástroj popisu

### DISKRÉTNÍ DATA

Primární data

Počty epizod pro  $n = 100$  hemofiliků

0  
0  
1  
2  
1  
1  
3  
1  
1  
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**

#### Primární data

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



#### Frekvenční summarizace

$n = 100$  opakování měření (100 pacientů)  
 $x$ : koncentrace sledované látky v krvi (20 – 100 jednotek)

Interval*	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  $X''$

\* Třídící interval


# Příklad: věk účastníků vážných dopravních nehod




# Jak vznikají informace ?

## - frekvenční summarizace spojitých dat

Histogram



Výběrová distribuční funkce



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

Intervalová  
hustota  
četnosti




$F(x)$

Intervalová  
relativní  
kumulativní  
četnost

# Histogram – počet intervalů




- 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.




- Dvě základní metody volby počtu intervalů  $m$ :
  - Odmocnina z celkového počtu:**  $\sqrt{N} = \sqrt{??}$
  - Storgesovo pravidlo:**  $1 + \log_2 N$

# Histogram vyjadřuje tvar výběrového rozložení




$f(x)$




$x$

$f(x)$




$x$











$x$

$f(x)$




$x$


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



# Pojem ROZLOŽENÍ - příklad spojitých dat



Hustota  
pravděpodobnosti  
=rozložení



Distribuční  
funkce

Je - li dána  
distribuční  
funkce,  
je dán  
rozložení

# Popisné statistiky



## Charakteristiky polohy (míry střední hodnoty, míry centrální tendencie)

- Udávají, kolem jaké hodnoty se data centrují, resp. které hodnoty jsou nejčastější, popis „těžiště“ – míry polohy
- Aritmetický průměr, medián, modus, geometrický průměr

## Charakteristiky variability (proměnlivosti)

- Zachycují rozptylení hodnot v souboru (proměnlivost dat)
- Variační rozpětí, rozptyl, směrodatná odchylka, variační koeficient, střední chyba průměru

# Nominální znaky



## Charakteristika polohy

- **Modus:** nejčastěji se vyskytující hodnota proměnné v souboru (hodnota s největší četností). V tabulce rozdelení četností se modus určí jednoduše z hodnoty znaku s největší četností.

# Ordinální znaky



## Charakteristika polohy

- **$\alpha$ -kvantil:** je-li  $\alpha \in (0,1)$ , pak  $\alpha$ -kvantil  $x_\alpha$  je číslo, které rozděluje uspořádaný datový soubor na dolní úsek, obsahující aspoň podíl  $\alpha$  všech dat a na horní úsek obsahující aspoň podíl  $1-\alpha$  všech dat.
- Pro speciálně zvolená  $\alpha$  užíváme názvů:  
 $x_{0,50}$ - **medián**,  $x_{0,25}$ - **dolní kvartil**,  $x_{0,75}$ - **horní kvartil**,  $x_{0,1}, \dots, x_{0,9}$ - **decily**
- **Medián** znamená hodnotu, jež dělí řadu podle velikosti seřazených výsledků na dvě stejně početné poloviny. Jestliže  $n$  je sudé číslo, pak  $\tilde{x} = 0,5(x_{\frac{n}{2}} + x_{\frac{n}{2}+1})$   
Jestliže  $n$  je liché číslo, pak  $\tilde{x} = x_{(n+1)/2}$

## Charakteristika variability

- **Kvartilové rozpětí (odchylka):**  $q = x_{0,75} - x_{0,25}$

# Intervalové a poměrové znaky I



## Charakteristika polohy

- **Aritmetický průměr:** je definován jako součet všech naměřených údajů vydělený jejich počtem,

$$E(x) = \bar{x} = \sum_{i=1}^n x_i / n \quad \text{kde } x_i \text{ jsou jednotlivé hodnoty a } n \text{ jejich počet}$$



- **Geometrický průměr:**  $n$  kladných hodnot  $x_i, \sqrt[n]{x_1 * \dots * x_n}$ , má smysl všude, kde má nějaký informační smysl součin hodnot proměnné. Z praktického hlediska platí, že logaritmus geometrického průměru je roven aritmetickému průměru logaritmovaných hodnot souboru.

# Průměr vs medián



## **PAMATUJ:**

- Průměr je silně ovlivněn extrémními hodnotami (tzv. odlehlá pozorování), medián není ovlivněn vybočujícími pozorováními
- Průměr je vhodný ukazatel středu u normálního/symetrického rozložení, medián je vhodnou charakteristikou středu souboru i v případě veličin s neznámým rozdělením
- V případě symetrického rozložení jsou jejich hodnoty v podstatě shodné, v případě asymetrického rozložení však nikoliv!



# Intervalové a poměrové znaky II



## Charakteristiky variability

- **Rozptyl (variance)** je ukazatelem šířky rozložení získaný na základě odchylky jednotlivých hodnot od průměru

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


Obdobně jako u průměru je jeho vypovídací schopnost nejvyšší v případě symetrického/normálního rozložení

- **Směrodatná odchylka (SD-standard deviation)** je druhá odmocnina z rozptylu
- **Koefficient variance** - podíl SD ku průměru, u poměrových znaků, umožňuje porovnat variabilitu několika znaků (často se vyjadřuje v procentech – potom udává, z kolika procent se podílí směrodatná odchylka na aritmetickém průměru)

# Ukazatele tvaru rozložení



- **Skewness (šikmost)** – ukazatel „šikmosti“ rozložení, asymetrie rozložení
- **Kurtosis (špičatost)** – ukazatel „špičatosti/plochosti“ rozložení



# Další parametry rozložení

---



- **Počet hodnot** – důležitý ukazatel, znamená jak moc lze na data spoléhat
- **Suma hodnot**
- **Minimum, maximum**
- **Variační rozpětí (rozsah)** – rozdíl mezi největší a nejménší hodnotou řady
- **Střední chyba průměru (SE)** – měří rozptylenost vypočítaného aritmetického průměru v různých výběrových souborech vybraných z jednoho základního souboru

# Ukázka popisu a vizualizace kvalitativních dat




- **Popis kvalitativních dat:** frekvence jednotlivých kategorií
- **Vizualizace kvalitativních dat:** nejčastěji koláčový nebo sloupcový graf

## Příklad: Známka z biostatistiky (podzim 2014)


**Frekvenční tabulka**

Známka	n	%
A	11	18,0
B	20	32,8
C	16	26,2
D	9	14,8
E	5	8,2
F	0	0,0
Celkem	61	100,0

**Koláčový graf**



**Sloupcový graf**



# Ukázka popisu kvantitativních dat



- **Popis kvantitativních dat:** charakteristika středu (průměr, medián aj.), charakteristika variability (rozptyl, rozsah hodnot, interkvartilové rozpětí aj.)

## Příklad: Popis výšky (cm) pacientů

### Popisné statistiky

Charakteristika	
N	61
Průměr (cm)	161,0
Medián (cm)	161,5
sm. odchylka (cm)	4,7
Rozptyl (cm <sup>2</sup> )	22,2
min-max (cm)	144,1 - 169,2
dolní-horní kvartil (cm)	158,1 - 164,2

Průměr a medián se téměř shodují. Co nám to říká?


# Ukázka vizualizace kvantitativních dat



- **Vizualizace kvantitativních dat:** nejčastěji pomocí krabicového grafu nebo histogramu

## Příklad: Popis výšky (cm) pacientů

Krabicový graf



Histogram

