

Biostatistika



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 procent**
- 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

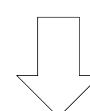


Jsou více nemocní muži nebo ženy?

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:

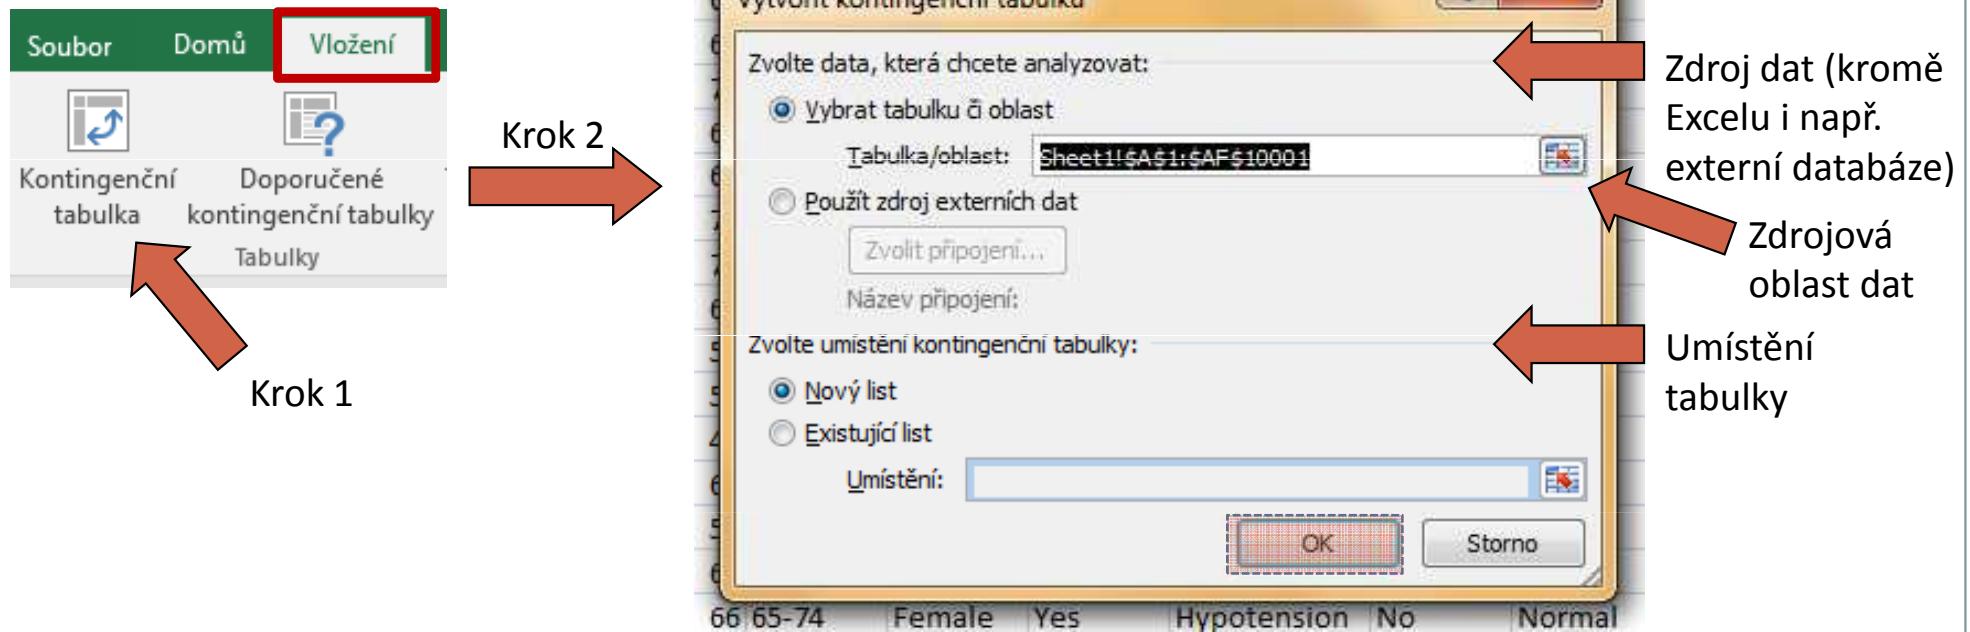
1. z tabulky v daném sešitě
2. z dat z jiného sešitu Excelu
3. z externích dat (např. MS Access)
4. ze sloučených dat z více oblastí - z různých listů nebo různých sešitů
5. z jiné kontingenční tabulky

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

A3 f_x

Kontingenční tabulka 1

Chcete-li vytvořit sestavu, zvolte pole ze seznamu polí kontingenční tabulky.

parametry na řádcích

parametry, které je možné zobrazit v kontingenční tabulce

parametry dat

parametry ve sloupcích

filtr

Seznam polí kontingenční tabulky

Zvolte pole, které chcete přidat do sestavy:

- age
- agecat
- gender
- diabetes
- bp
- smoker
- choles
- active
- obesity
- angina
- mi
- nitro
- antidrt

Přetáhnout pole mezi následujícími oblastmi:

- Filtr sestavy
- Popisky sloupců
- Popisky řádků
- Σ Hodnoty

Odložit aktualizaci rozložení Aktualizovat

Seznam polí kontingenční tabulky

Zvolte pole, které chcete přidat do sestavy:

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

Přetáhnout pole mezi následujícími oblastmi:

- Filtr sestavy
- Popisky sloupců
- Popisky řádků
- Σ Hodnoty

smoker

agecat

Počet z agecat

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
Celkový součet	7725	2275	10000

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
Celkový součet	7725	2275	10000

Aktualizace dat v kontingenční tabulce



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

Musíte provést aktualizaci dat.

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

The screenshot shows the Microsoft Excel ribbon. The 'Analýza' tab is highlighted with a red box. A large red arrow points from the text 'Aktualizace dat' to the 'Aktualizovat' button in the 'Data' group of the ribbon. The ribbon also includes tabs for 'Zobrazení', 'Návrh', and 'Nástroje kontingenční tabulky'. The main window title is 'spolecne_cviceni_Konting_řešení.xlsx - Excel'. The 'Data' group contains icons for 'Aktualizovat', 'Změnit zdroj dat', 'Vymazat', 'Vybrat', 'Přesunout', and 'Akce'.

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!

Kontingenční graf



Data z kontingenční tabulky lze vizualizovat pomocí kontingenčního grafu.

Návod: Na kartě **Analýza** ve skupině **Data** klikněte na **Kontingenční graf**.

The screenshot shows the Microsoft Excel ribbon with the 'Analýza' tab selected (highlighted with a red box). A red arrow points from the text above to the 'Kontingenční graf' button in the 'Nástroje' group on the far right of the ribbon. The window title is '02_spolecne_cviceni_Konting_řešení.xlsx - Excel'.

Příklad
kontingečního
grafu:



II. Základy popisné statistiky



Typy proměnných



Kvalitativní (kategoriální) proměnná

- lze ji řadit do kategorií, ale nelze ji kvantifikovat

Příklad: ??

Kvantitativní (numerická) proměnná

- můžeme jí 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),

stádium 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 ¹	Podíl ¹
1.	2 °C	-	-
2.	4 °C	+2	2x
3.	6 °C	+2	1.5x

¹ 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, ...

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

Charakteristiky polohy



Charakteristiky polohy u nominálních znaků

- **Modus:** nejčastěji se vyskytující hodnota proměnné v souboru.

Charakteristiky polohy u ordinálních znaků

- **α -kvantil:** je-li $\alpha \in (0,1)$, pak α -kvantil x_α je číslo, které rozděluje uspořádaný datový soubor na dolní úsek, obsahující aspoň podíl α všech dat a na horní úsek obsahující aspoň podíl $1-\alpha$ všech dat.
- $x_{0,50}$ - **medián**, $x_{0,25}$ - **dolní kvartil**, $x_{0,75}$ - **horní kvartil**, $x_{0,1}, \dots, x_{0,9}$ - **decily**
- **Medián:** hodnota, jež dělí řadu podle velikosti seřazených výsledků na dvě stejně početné poloviny.

Charakteristiky polohy



Charakteristiky polohy u intervalových a poměrových znaků

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

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

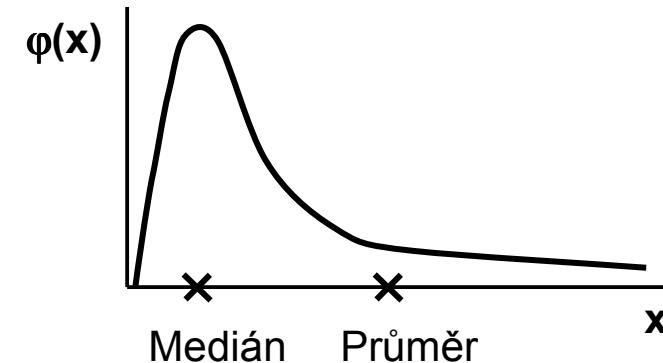
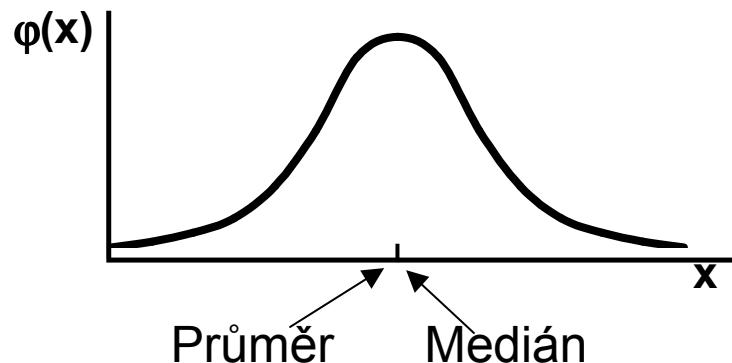
- **Geometrický průměr:** n kladných hodnot $x_i, \sqrt[n]{x_1 * \dots * x_n}$, má smysl všude, kde má nějaký informační smysl součin hodnot proměnné. Z praktického hlediska platí, že logaritmus geometrického průměru je roven aritmetickému průměru logaritmovaných hodnot souboru.

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 asymetrickým či neznámým rozdělením
- V případě symetrického rozložení jsou jejich hodnoty v podstatě shodné, v případě asymetrického rozložení však nikoliv!



Charakteristiky variability



Charakteristiky variability u ordinálních znaků

- **(Inter)kvartilové rozpětí (odchylka; IQR):** $q = x_{0,75} - x_{0,25}$

Charakteristiky variability u intervalových a poměrových znaků

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

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

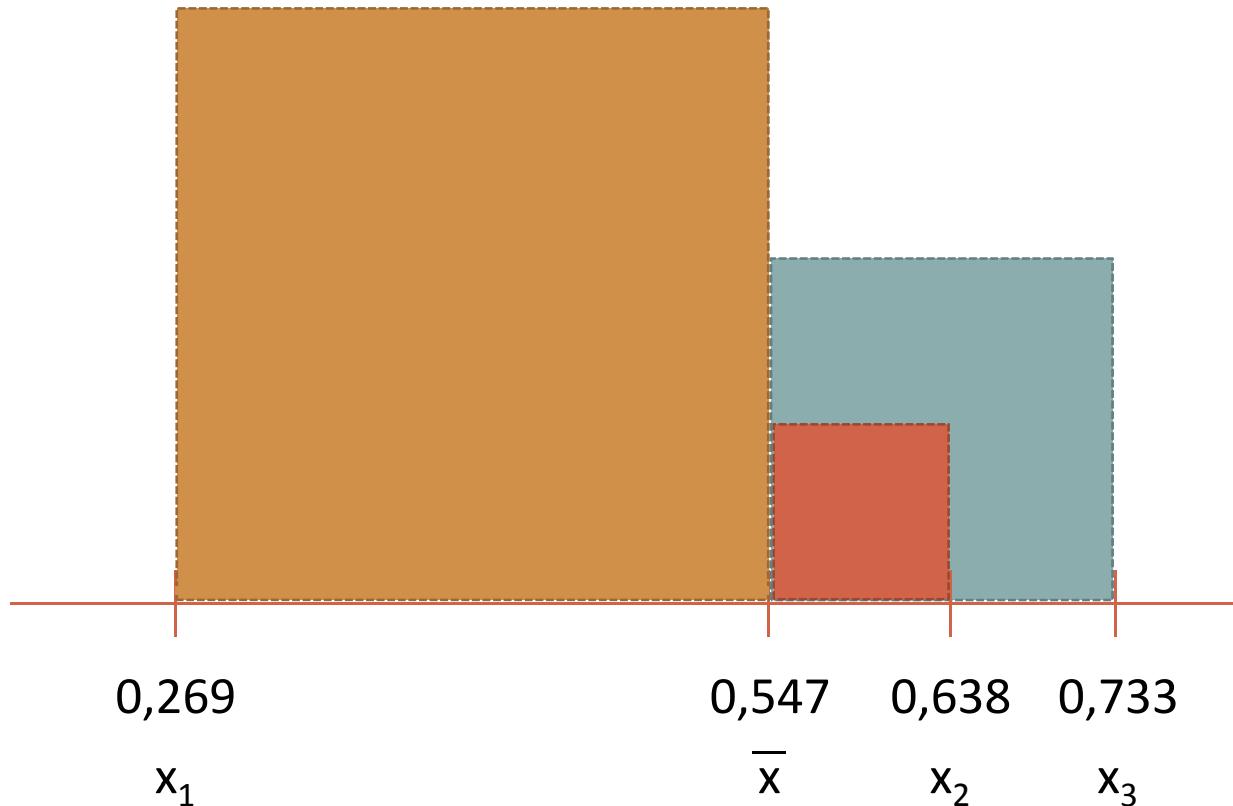
Jeho vypovídací schopnost nejvyšší v případě symetrického/normálního rozložení

- **Směrodatná odchylka** je druhá odmocnina z rozptylu
- **Koefficient variance** - podíl SD ku průměru, u poměrových znaků, umožňuje porovnat variabilitu několika znaků (vyjadřuje se v %)

Výpočet rozptylu a směrodatné odchylky



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



Rozptyl:

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

Směrodatná odchylka:

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

Další parametry rozložení



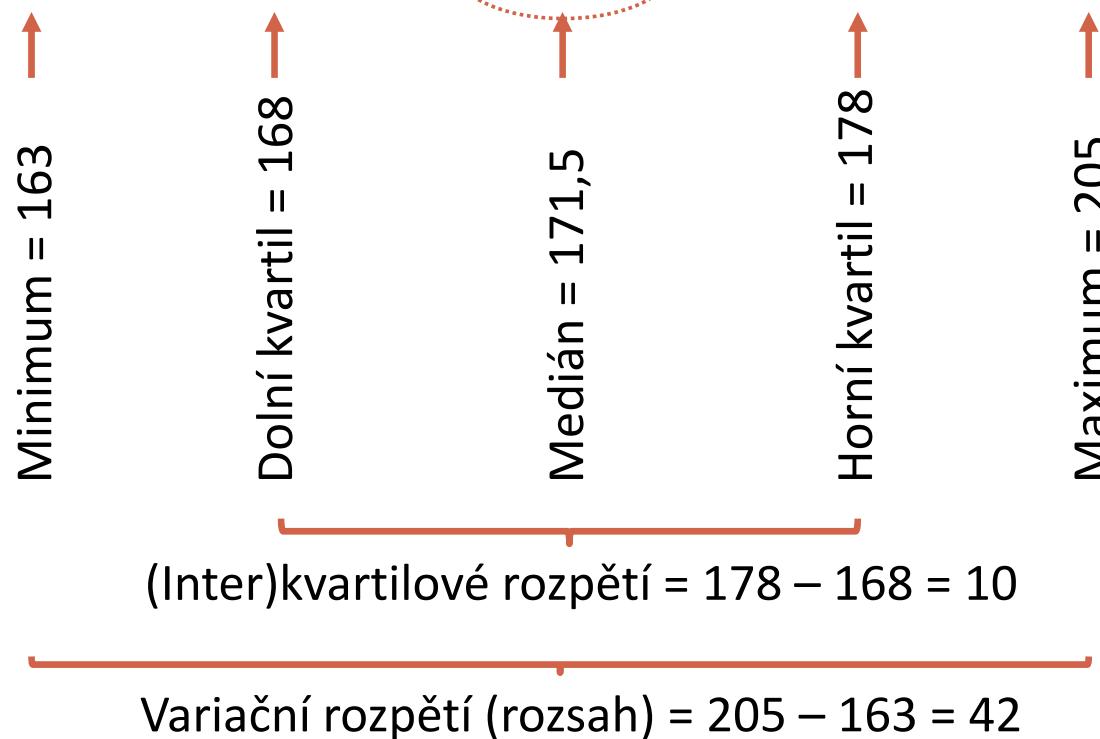
- **Počet hodnot** – důležitý ukazatel, znamená, jak moc lze na data spoléhat
- **Suma hodnot**
- **Minimum, maximum**
- **Variační rozpětí (rozsah)** – rozdíl mezi největší a nejménší hodnotou řady
- **Střední chyba průměru (SE)** – měří rozptylenost vypočítaného aritmetického průměru v různých výběrových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

Popisná summarizace kvantitativních dat - příklad



Data – výška studentů (v cm): 178, 163, 205, 172, 168, 165, 179, 178, 169, 171

Seřazená data: 163, 165, 168, 169, 171, 172, 178, 178, 179, 205



Průměr: $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i / n = (178+163+205+172+168+165+179+178+169+171)/10 = 174.8$

Ukázka popisu a vizualizace kvalitativních dat



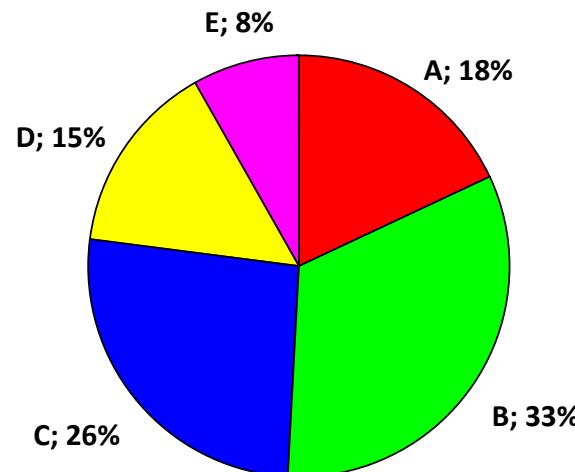
- **Popis kvalitativních dat:** frekvence jednotlivých kategorií
- **Vizualizace kvalitativních dat:** nejčastěji koláčový nebo sloupcový graf

Příklad: Známka z biostatistiky (podzim 2014)

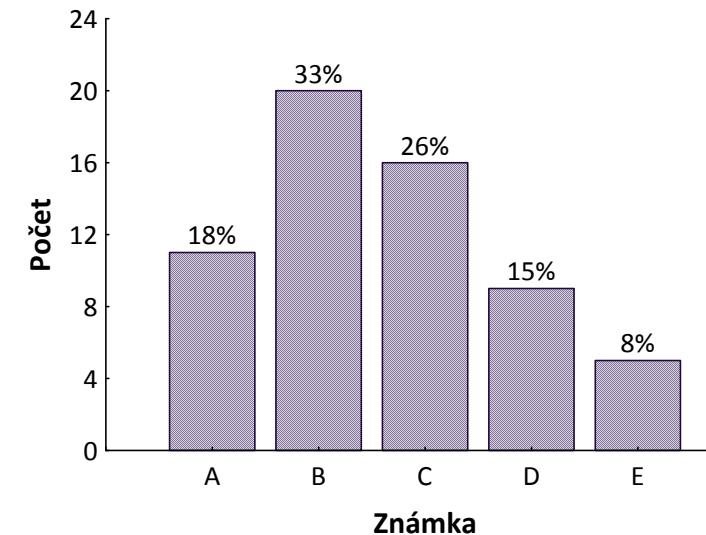
Frekvenční tabulka

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 ²)	22,2
min-max (cm)	144 – 169
dolní-horní kvartil (cm)	158 - 164

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

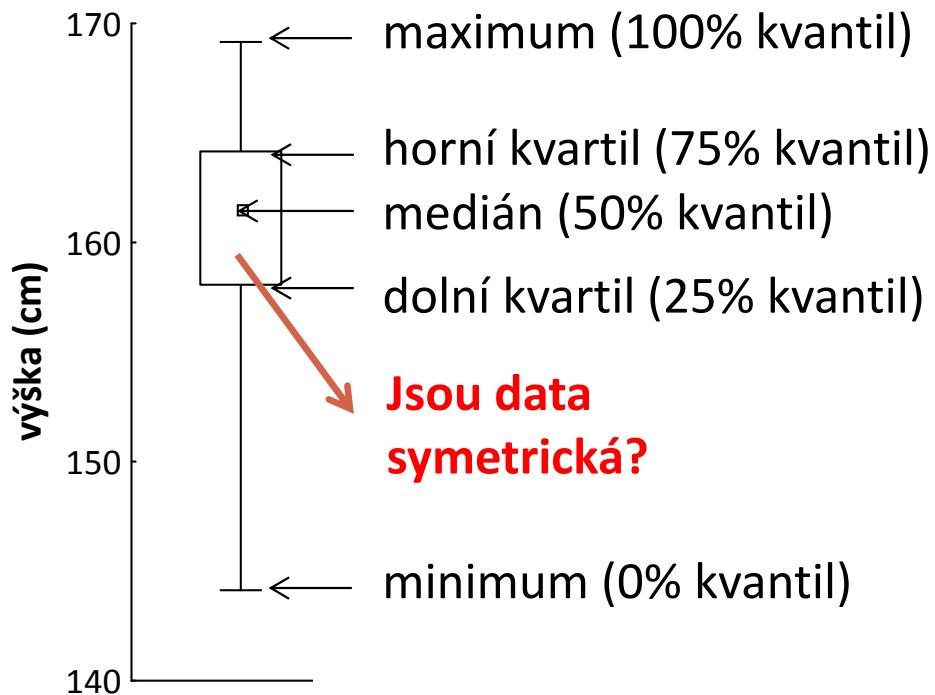
Ukázka vizualizace kvantitativních dat



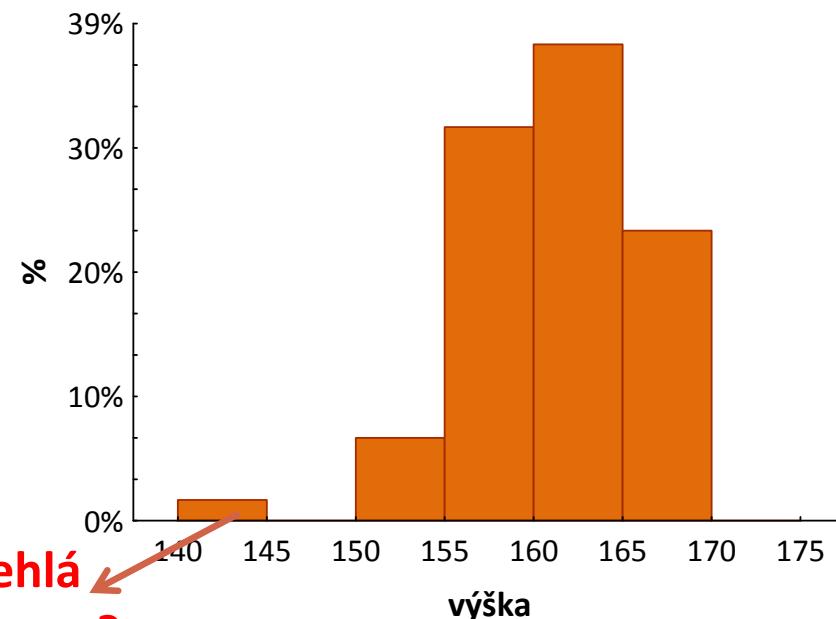
- **Vizualizace kvantitativních dat:** nejčastěji pomocí krabicového grafu nebo histogramu

Příklad: Popis výšky (cm) pacientů

Krabicový graf



Histogram



III. Cvičení v programu Statistica



**Základní popisné statistiky
v programu Statistica
Datový soubor pacienti.sta
Datový soubor studenti.sta**

Program Statistica



Jak získat program Statistica:

<https://inet.muni.cz>

Login a heslo: UČO a primární heslo jako do IS-u.

V nabídce kliknout na: **Provozní služby – Software – Nabídka softwaru**

Nalézt: **Statistica 13.3** – kliknout **Získat**

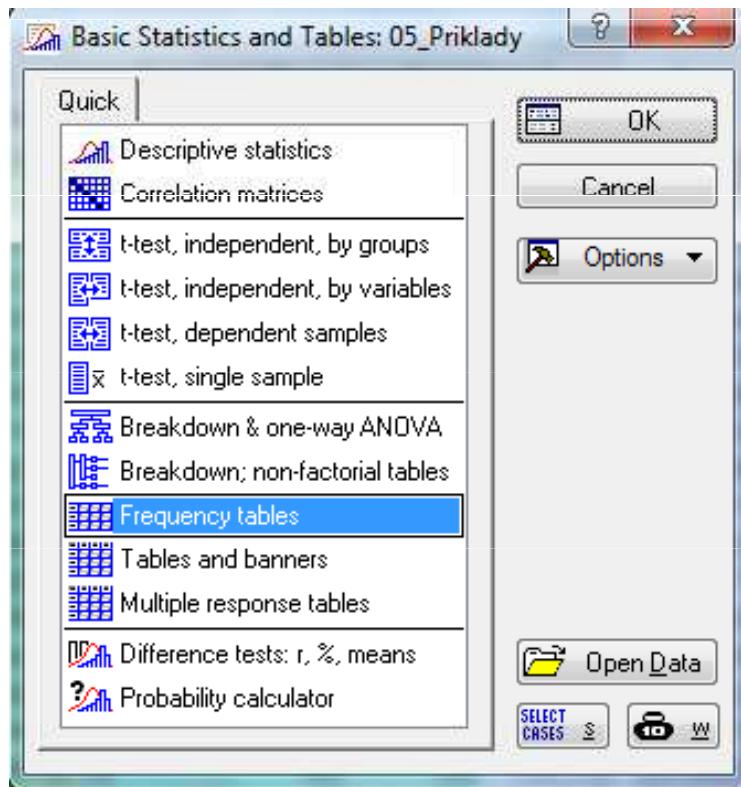
Postupovat dle návodu

Základy popisné statistiky: soubor pacienti.sta



Načtěte soubor **pacienti.sta**, který obsahuje údaje o 61 pacientech.

- Nejprve budeme pracovat s kategoriální proměnnou.
- Pro proměnnou pohlaví zjistěte: absolutní, relativní četnost, dále absolutní a relativní kumulativní četnost



Postup: Statistics – Basic Statistics – Frequency tables

Category	Frequency table: Pohlavi: =Round(Rnd(1);0) (05_F)			
	Count	Cumulative Count	Percent	Cumulative Percent
muz	31	31	50,81967	50,8197
zena	30	61	49,18033	100,0000
Missing	0	61	0,00000	100,0000

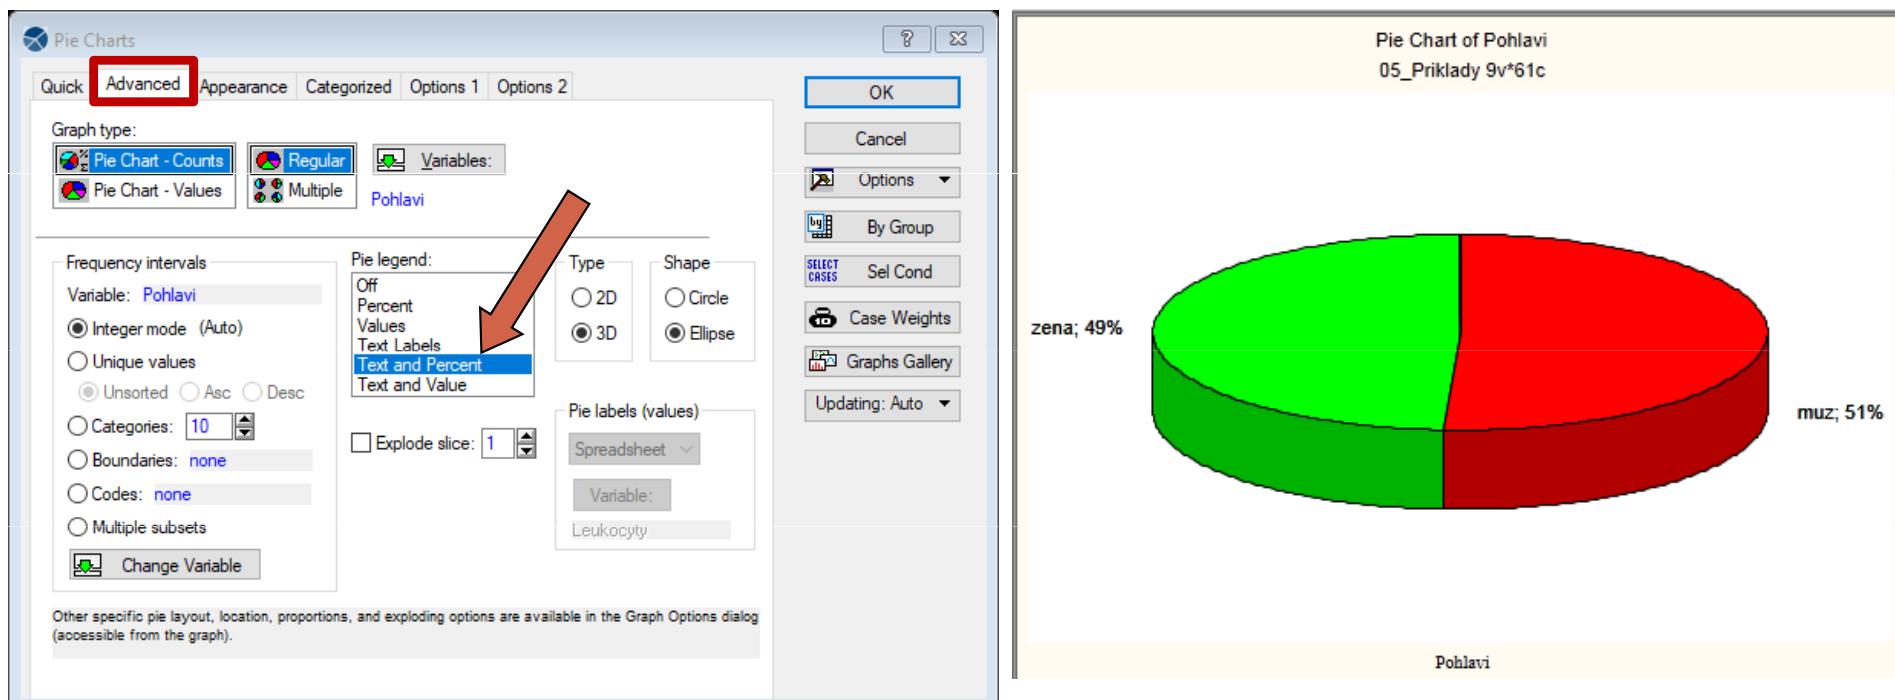
Základy popisné statistiky: soubor pacienti.sta



- Pomocí výsečového grafu (koláčového grafu) znázorněte proměnnou Pohlaví, doplňte procenta (relativní četnost).**

Postup vytvoření grafu: Graphs – 2D – Pie Charts...

Postup přidání legendy: na záložce Advanced kliknout na „Text and Percent“

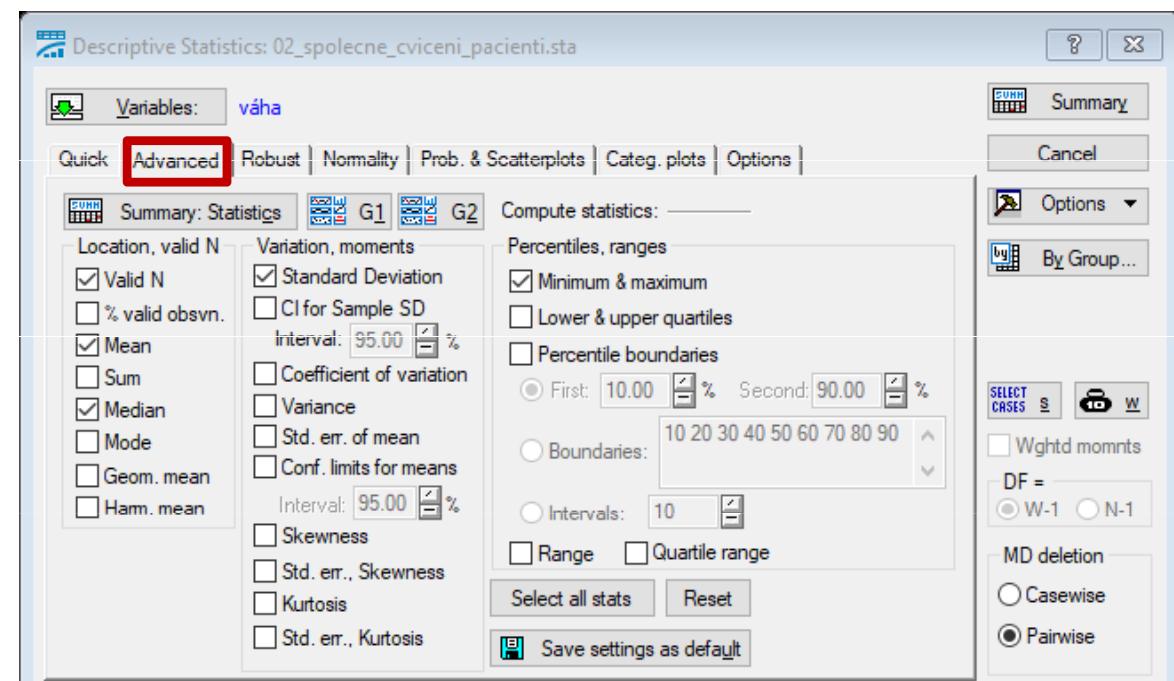
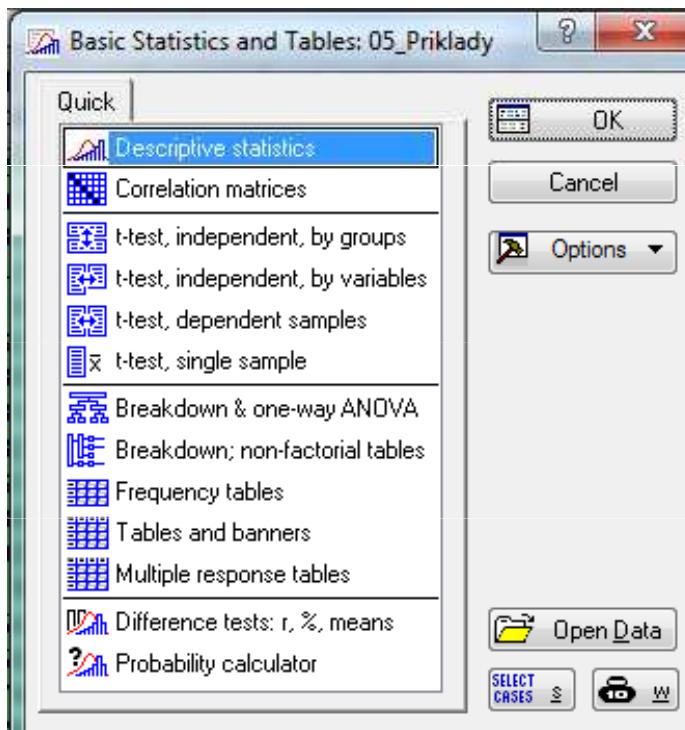


Základy popisné statistiky: soubor pacienti.sta



- **Nyní budeme pracovat se spojitou proměnnou.**
- **Pro proměnnou váha zjistěte: průměr, medián, minimum, maximum a směrodatnou odchylku**

Postup: Statistics – Basic Statistics
– Descriptive statistics

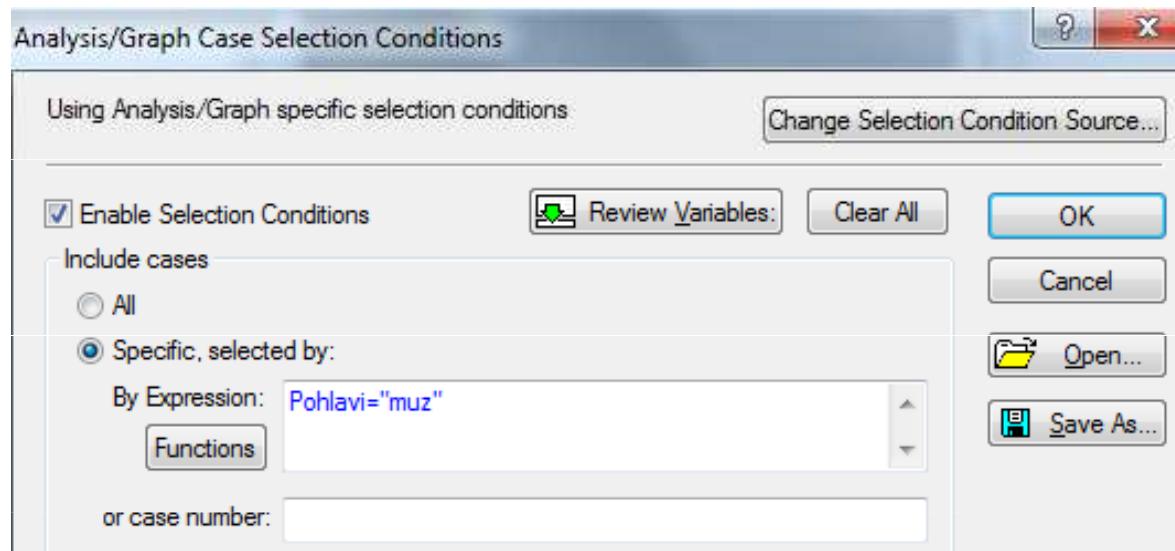


Variable	Descriptive Statistics (05_Priklady)					
	Valid N	Mean	Median	Minimum	Maximum	Std.Dev.
váha	61	65,63968	66,49219	49,80155	79,20183	4,988461

Základy popisné statistiky: soubor pacienti.sta



- Pokud bychom chtěli zjistit průměrnou váhu pouze u mužů, klikneme na tlačítko **SELECT CASES** a zvolíme Pohlaví="muz" (nezapomínejte na uvozovky)



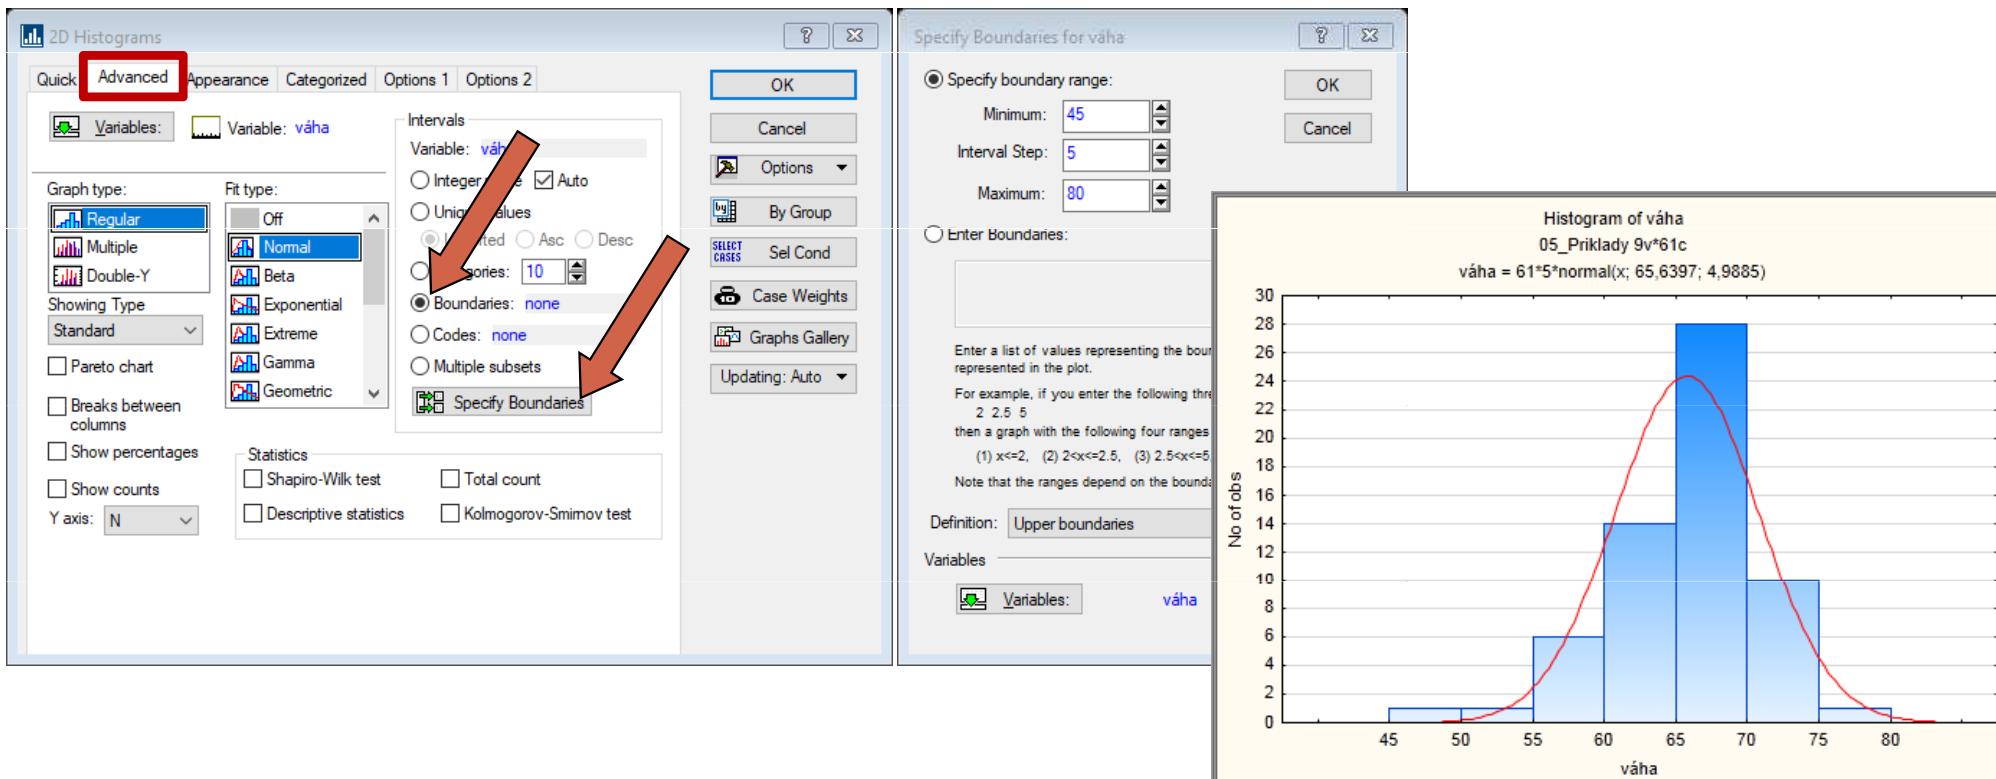
Descriptive Statistics (05_Priklady) Include condition: Pohlavi="muz"					
Variable	Valid N	Mean	Minimum	Maximum	Std.Dev.
váha	31	65,37337	49,80155	72,14984	5,034108

Základy popisné statistiky: soubor pacienti.sta



- Vytvořte histogram s rozpětím hodnot po pěti, poté zkuste to samé pro muže a ženy.**

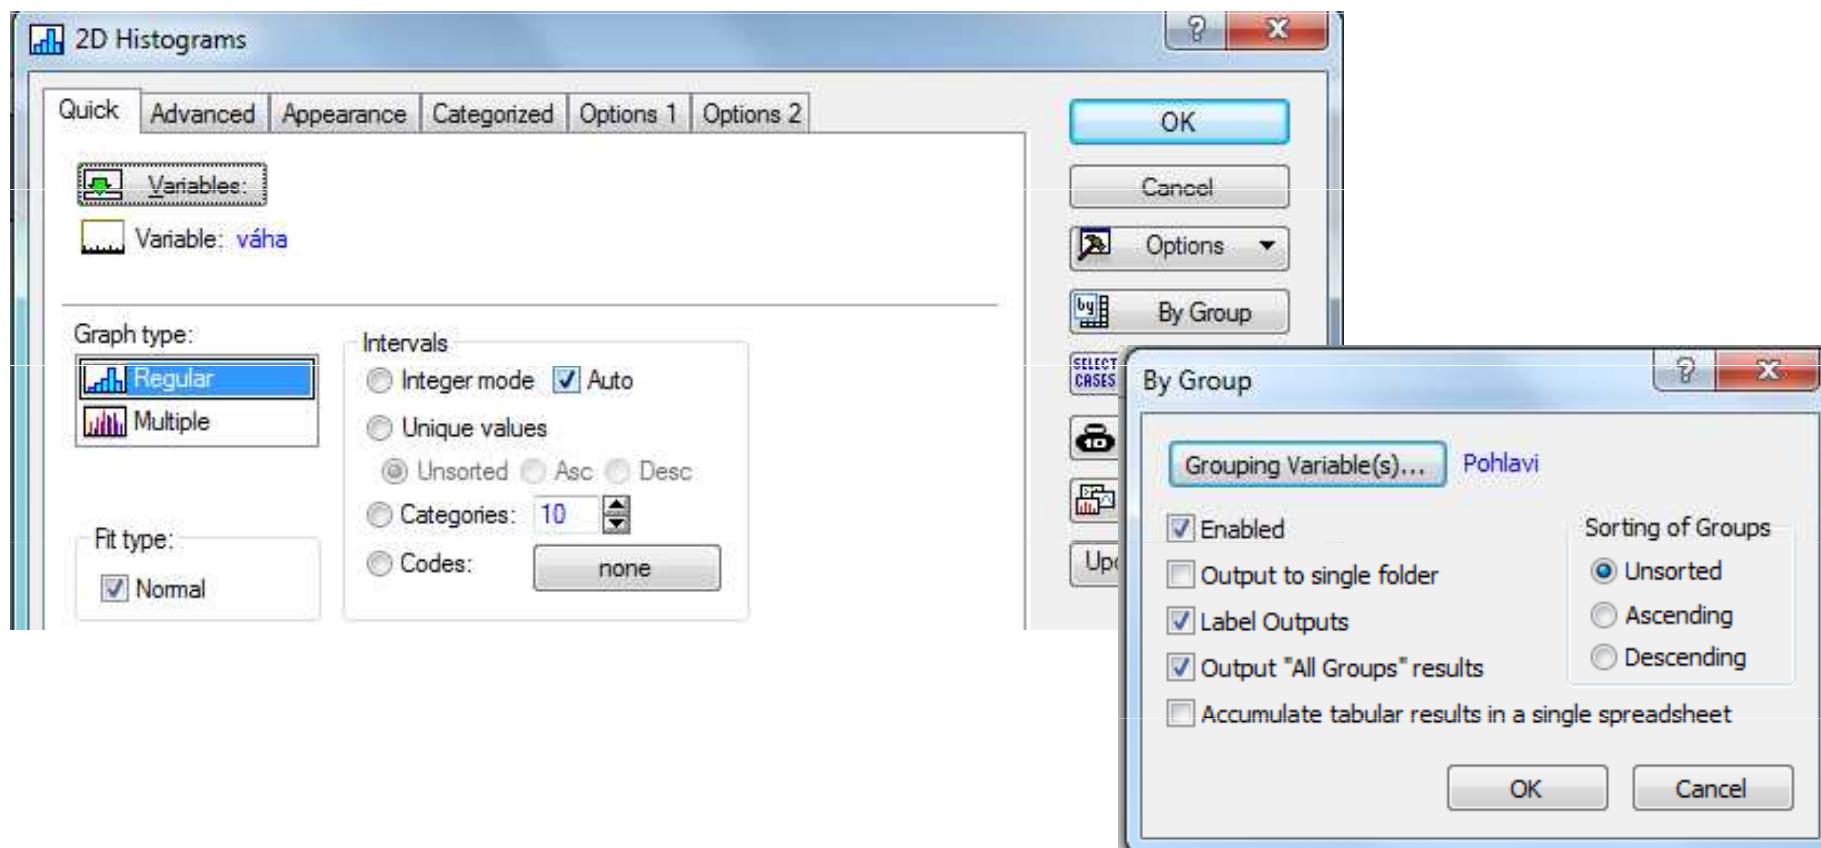
Postup: Záložka Graphs -> Histogram -> proměnná váha, záložka Advanced: zatrhnout Boundaries -> Specify Boundaries



Základy popisné statistiky: soubor pacienti.sta



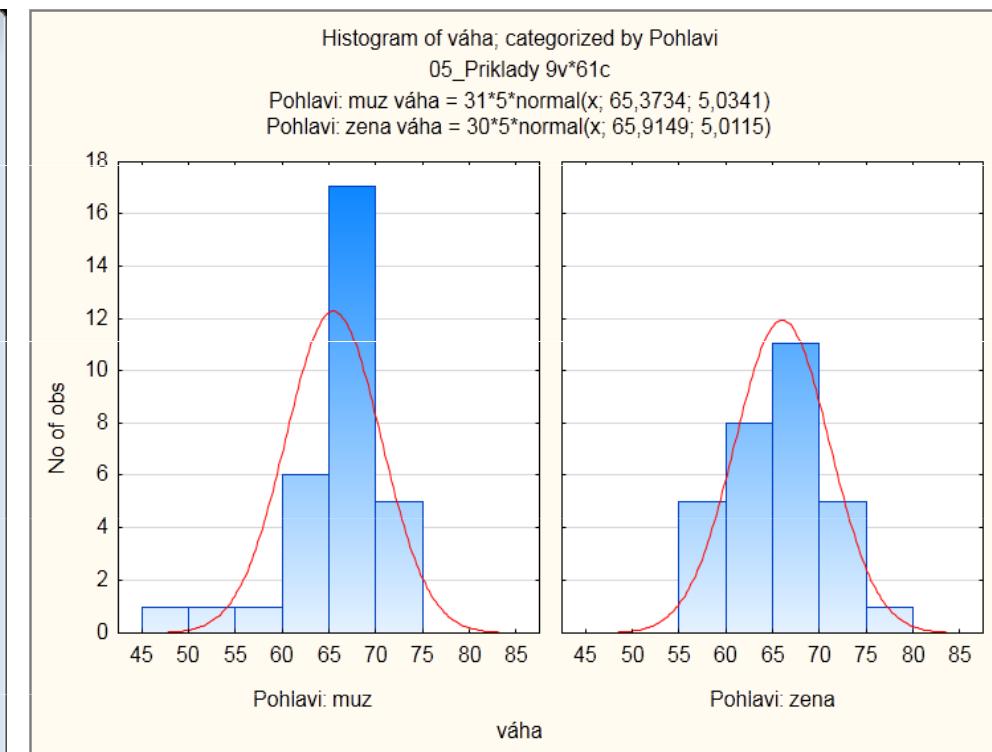
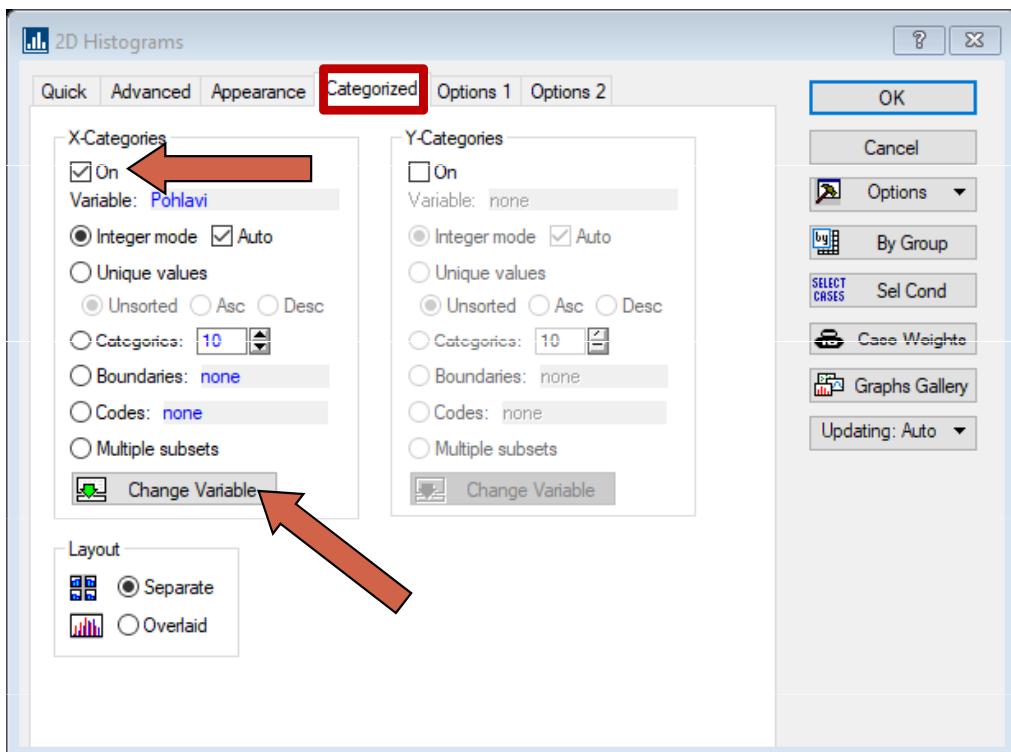
- Pokud chceme váhu oddeleně pro pohlaví - po boku vpravo By group: vybereme proměnnou pohlaví.



Základy popisné statistiky: soubor pacienti.sta



- Pokud chceme histogram váhy pro muže i ženy mít v jednom grafu: vybereme záložku Categorized, zapneme kategorii X a změníme proměnnou na pohlaví.**

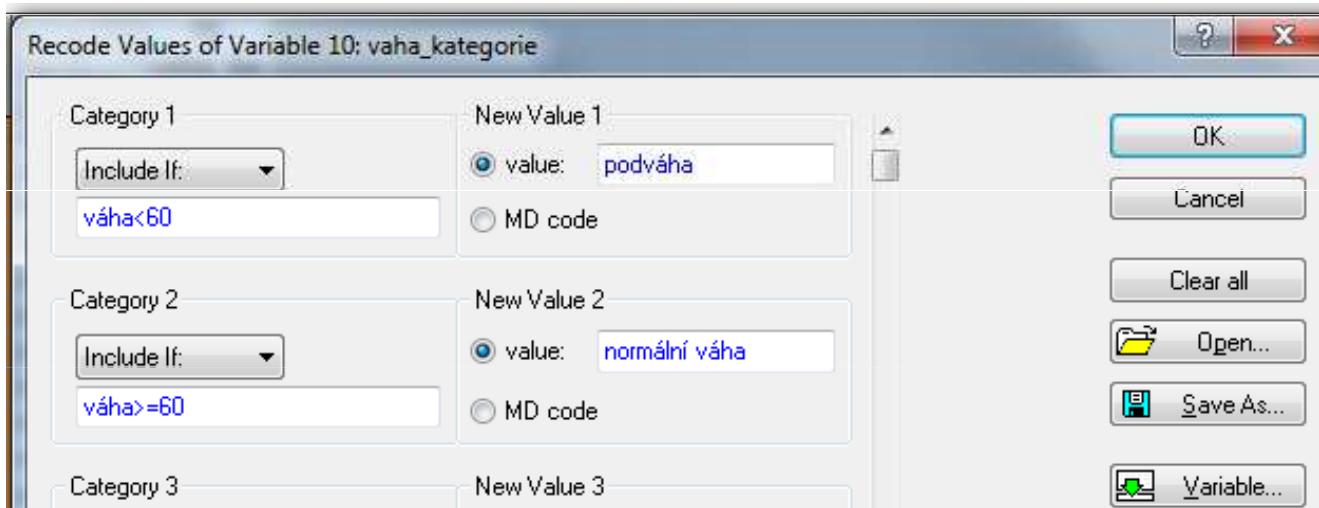


Základy popisné statistiky: soubor pacienti.sta



- **Překódování proměnné:**
- *Proměnnou váha překódujte do proměnné vaha_kategorie tak, aby pacienti pod 60 kg tvořili jednu skupinu a pacienti 60+ druhou skupinu.*

Návod: Vložíme novou proměnnou vaha_kategorie za proměnnou váha. Označíme novou proměnnou vaha_kategorie, záložka Data -> Recode



- **Zjistěte, kolik % žen mělo váhu pod 60 kg?**

Samostatné cvičení: soubor studenti.sta



Načtěte soubor studenti.sta, který obsahuje údaje o 26 studentech, získané informace jsou shrnuty v proměnných A,B,C,D.

Návod: Záložka *Home* → *Open* → vybereme soubor studenti.sta.

Změňte názvy proměnných: A-jméno studenta, B-známka z biostatistiky, C-pohlaví, D-věk. U proměnných B a C popište jednotlivé varianty (proměnná B odpovídá známce: 1- výborně, 2- velmi dobře, 3- dobře, 4- nedostatečně; proměnná C odpovídá pohlaví:1 - muž, 2 - žena)

Návod: Vybereme nejprve příslušnou proměnnou A, 2krát klikneme myší → do položky *Name* napíšeme nový název proměnné (*All Specs...* umožní přejmenovat všechny proměnné najednou; *Text Labels* číselným hodnotám přiřadí textový popisek).

Pojmenujte názvy řádků tabulky jmény studentů, poté proměnnou jméno studenta smažte.

Návod: Záložka *Data* → *Names* → *Transfer case names from* → *Variable*: Jméno studenta;
smažání-vybereme proměnnou Jméno studenta, pravé tlačítko myši → *Delete Variable*.

Samostatné cvičení: soubor studenti.sta



U proměnné Známka zjistěte absolutní, relativní četnost, dále absolutní a relativní kumulativní četnost.

Návod: Záložka *Statistics* → *Basic Statistics* → *Frequency tables* → *Variables*: známka z biostatistiky → *Summary*

Zjistěte průměr, medián pro proměnnou Věk. U proměnné pohlaví zjistěte modus.

Pro proměnnou známka zjistěte medián, modus.

Návod:

Způsob 1: Označíme proměnnou věk, pravé tlačítko → *Statistics of Block Data* → *Blocks columns* → *All*

Zbůsob 2: Záložka *Statistics* → *Basic Statistics* → *Descriptive statistics* → *Variables*: věk → záložka *Advanced* → vybereme *Mean, Median*.

Samostatné cvičení: soubor studenti.sta



Proměnnou věk překódujte pomocí následujících 5 intervalů: **<20,22>, (22,25>, (25,28>, (28,31>, (31,33>** do proměnné Věk 2.

Návod: Vložíme novou proměnnou Věk 2 za proměnnou Věk. Označíme novou proměnnou

Věk 2, záložka *Data* → *Recode* → *Category 1*: věk>=20 and věk<=22, *New Value*: 1 atd.

Pomocí koláčového grafu znázorněte proměnnou Známku a Pohlaví, doplňte procenta (relativní četnost).

Návod: Záložka *Graphs* → *2D* → *Pie Charts* → Záložka: *Quick*: *Variables*: Známka, Pohlaví; Záložka: *Advanced* → *Pie legends* vyber *Text and Percent*.

Pomocí sloupcového grafu znázorněte věk pouze pro muže.

Návod: Záložka *Graphs* → *2D* → *Bar/Column Plots* → *Variables*: Věk, v tomtéž okně napravo klikneme na *Select Cases* → zaškrtneme možnost *Enable Selection Conditions* → *Specific* → *selected by Expression*: Pohlaví=1.

Samostatné cvičení: soubor studenti.sta



Pro proměnnou Věk vytvořte histogram s intervaly širokými dva roky, poté zkuste to samé zvlášť pro muže a ženy.

Návod: Záložka *Graphs* → *Histogram* → *Variables*: věk, záložka *Advanced: Intervals Boundaries* → *Specifies boundaries* po boku vpravo *By group*: vybereme proměnnou pohlaví