

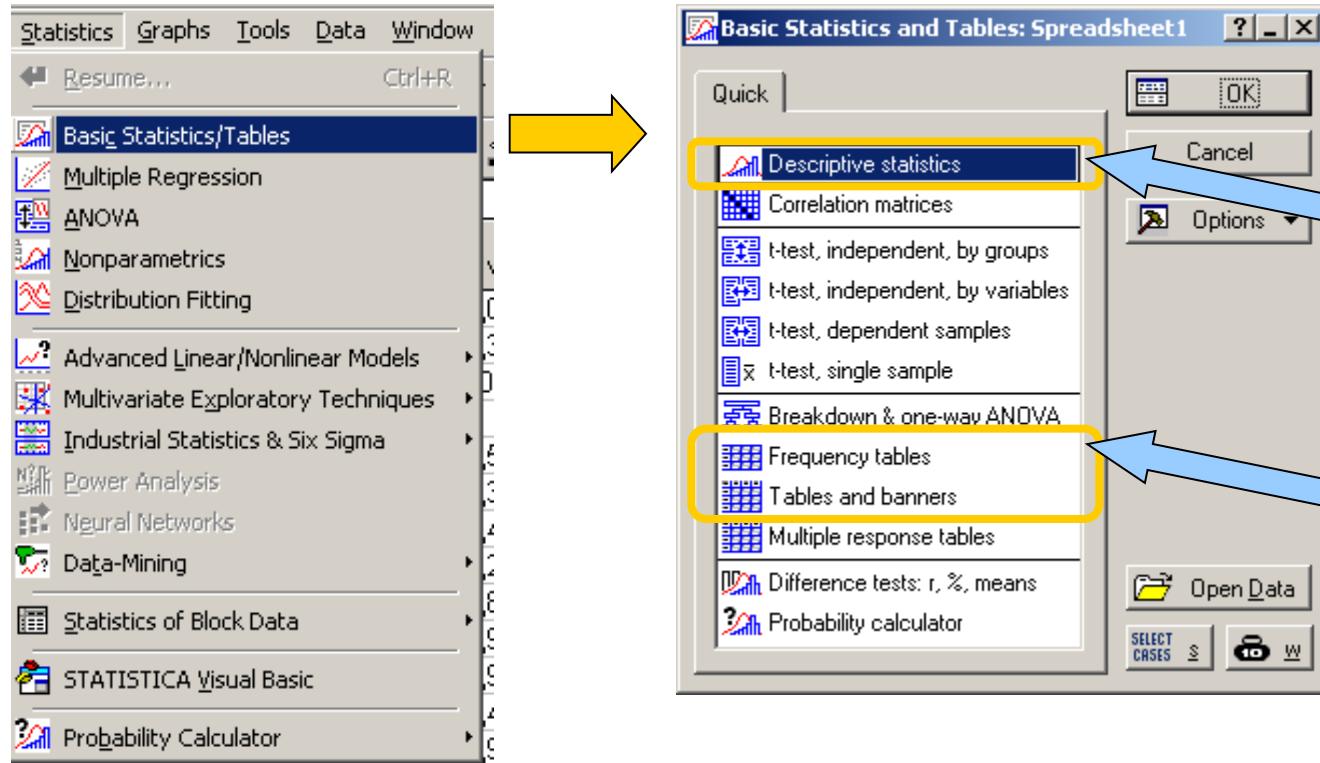
Analýza dat na PC I.

Popisná analýza v programu Statistica

IBA výuka

Analýza dat na PC I.

Základní popisná statistika



Popisná statistika

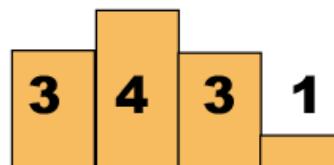
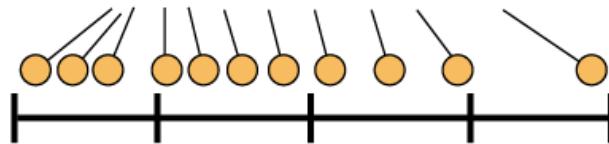
Frekvenční
tabulky, analýza
kontingenčních
tabulek

Typy proměnných

- ◆ **Kvalitativní/kategorická**
 - ◆ binární - ano/ne
 - ◆ nominální - A,B,C ... několik kategorií
 - ◆ ordinální - 1<2<3 ...několik kategorií a můžeme se ptát, která je větší
- ◆ **Kvantitativní**
 - ◆ nespojitá – čísla, která však nemohou nabývat všech hodnot (např. počet porodů)
 - ◆ spojité – teoreticky jsou možné všechny hodnoty (např. krevní tlak)

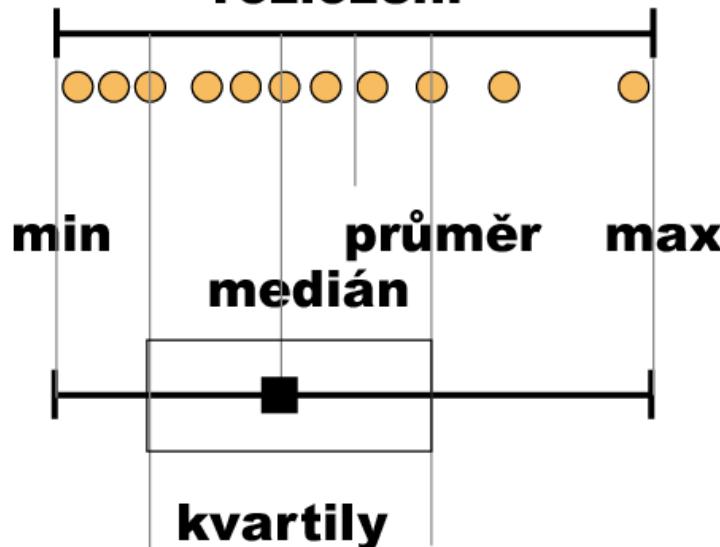
Řada dat a její vlastnosti

Jednotlivé hodnoty



Počty hodnot v kategoriích

Parametry rozložení



Box & whisker plot

Frekvenční rozložení

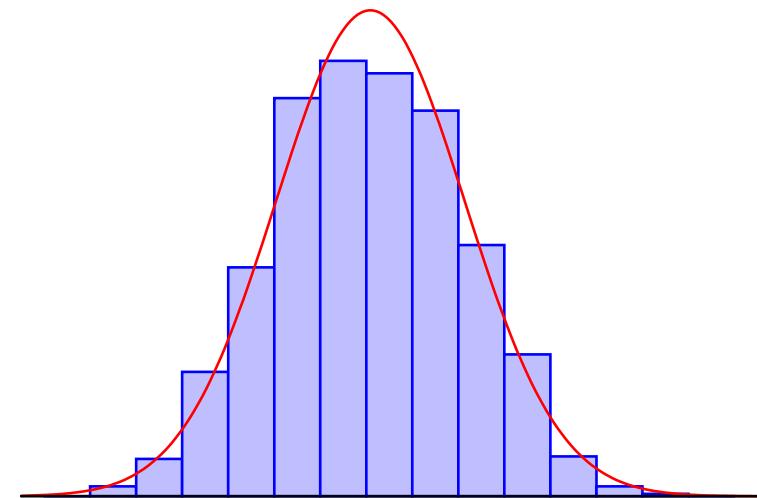
| Kategorie | Četnost |
|-----------|---------|
| B | 5 |
| C | 8 |
| D | 1 |

Kvalitativní data

Tabulka s četností jednotlivých kategorií.

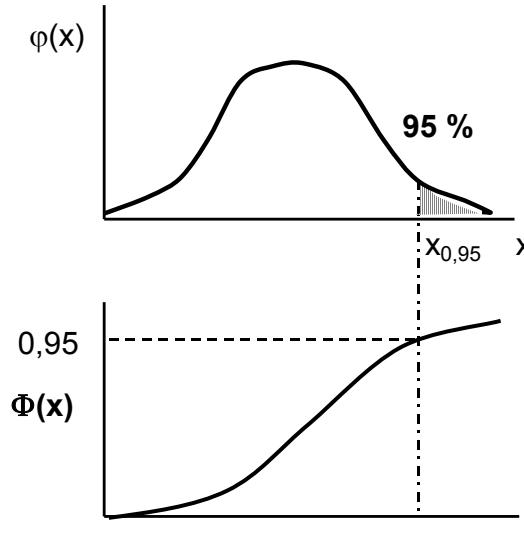
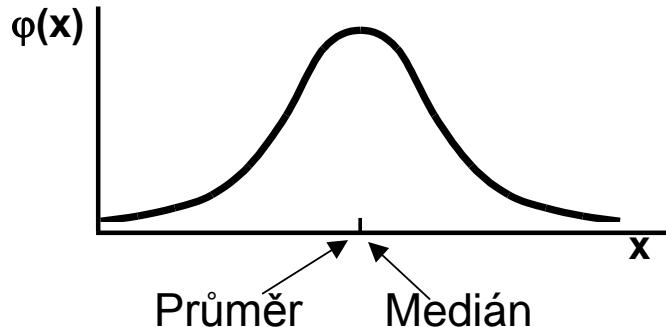
Kvantitativní data

Četnost hodnot rozložení v jednotlivých intervalech.



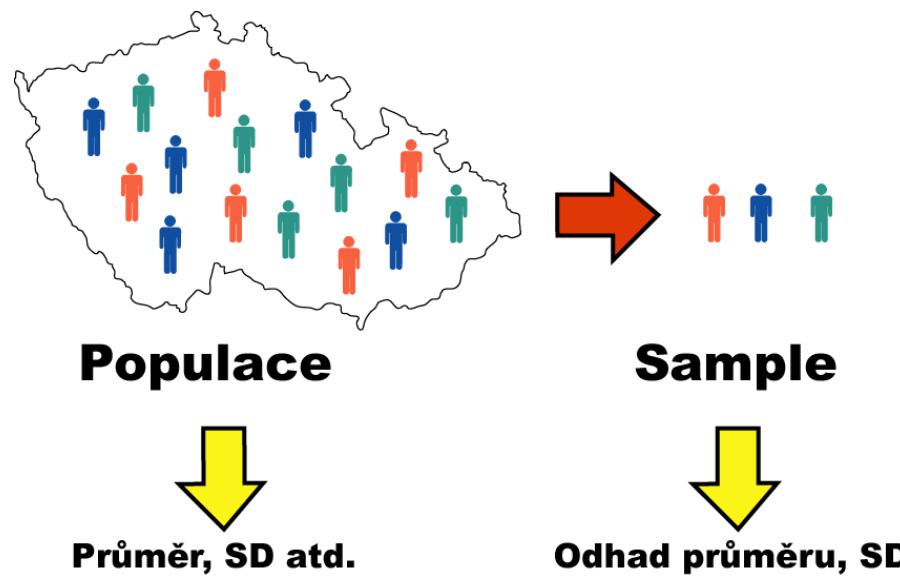
Parametry rozložení

- ◆ Soubor dat (řada čísel) můžeme charakterizovat parametry jeho rozložení
- ◆ Hlavní skupiny těchto parametrů můžeme charakterizovat jako ukazatele:
 - ◆ Středu (medián, průměr, geometrický průměr)
 - ◆ Šířky rozložení (rozsah hodnot, rozptyl, směrodatná odchylka)
 - ◆ Tvaru rozložení (skewness, kurtosis)
 - ◆ Kvantily rozložení – kolik % řady dat leží nad a pod kvantilem



Populace a vzorek

- ◆ Populace představuje veškeré možné objekty vzorkování, např. veškeré obyvatelstvo ČR při sledování na úrovni ČR, z populace získáme reálné parametry rozložení
- ◆ Z populace je prováděno vzorkování za účelem získání reprezentativního vzorku (**sample**) populace, toto vzorkování by mělo být náhodné, důležitá je také velikost vzorku, ze vzorku získáme odhady parametrů rozložení

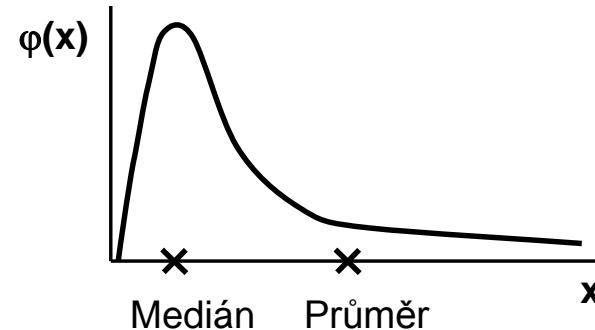
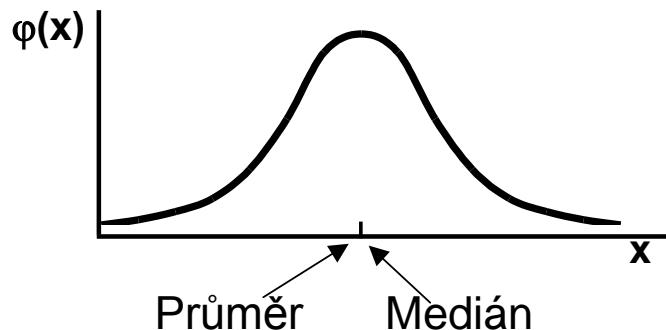


Ukazatele středu rozložení I

- ◆ **Průměr** – vhodný ukazatel středu u normálního/symetrického rozložení, kde x_i jsou jednotlivé hodnoty a n jejich počet

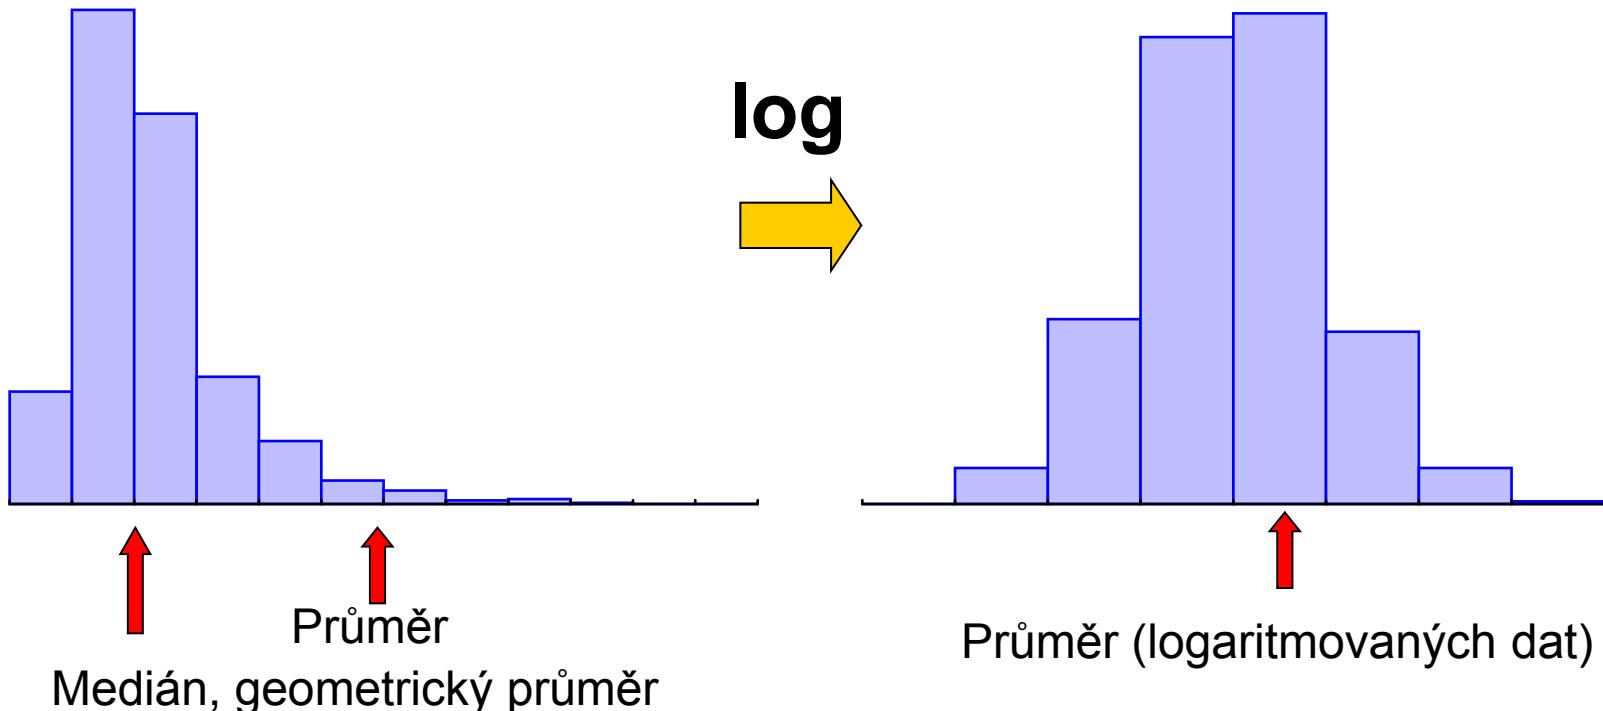
$$E(x) = \bar{x} = \sum_{i=1}^n \frac{x_i}{n}$$

- ◆ **Medián** – jde vlastně o 50% kvantil, tj. polovina hodnot leží nad a polovina pod mediánem
- ◆ V případě symetrického rozložení jsou jejich hodnoty v podstatě shodné



Ukazatele středu rozložení II.

- ◆ Geometrický průměr – antilogaritmus průměru logaritmovaných dat, je vhodný pro doleva asymetrická data (lognormální rozložení), která jsou v biologii velmi častá, jeho hodnota v podstatě odpovídá mediánu
- ◆ Takto asymetrická data je možné převést logaritmickou transformací na

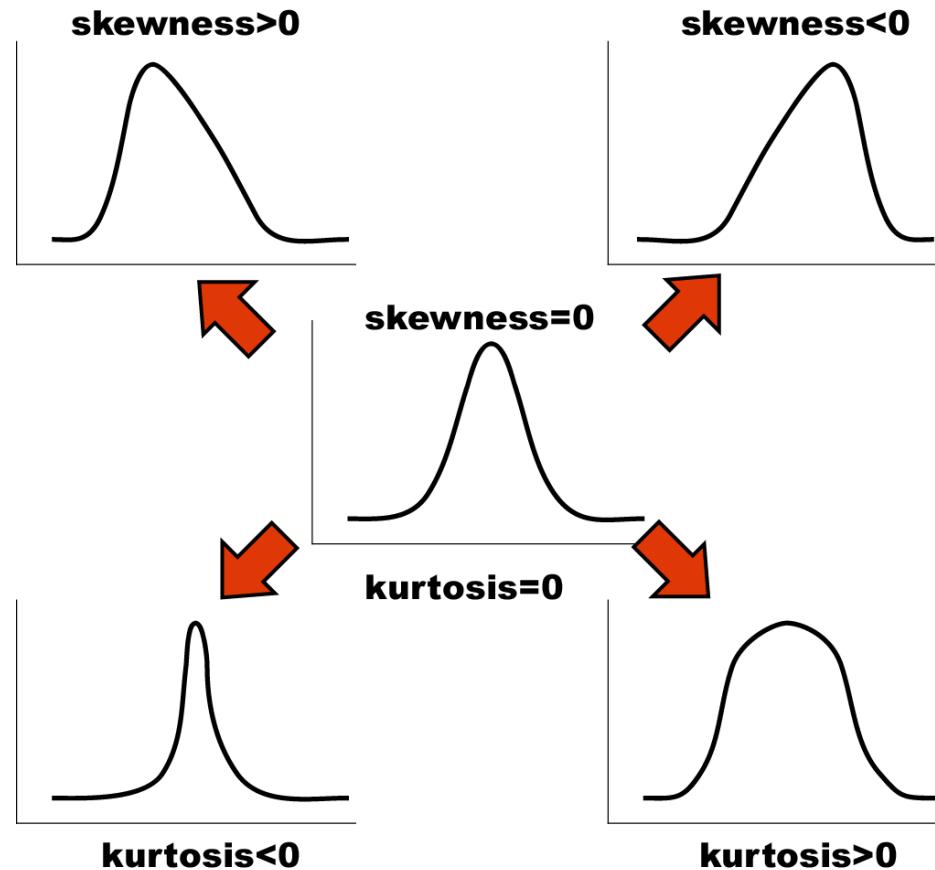


Ukazatele šířky rozložení

- ◆ **Rozptyl** 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** je druhá odmocnina z rozptylu
- ◆ **Koefficient variance** - podíl SD ku průměru (u normálního rozložení by se 95% hodnot mělo vejít do průměr ± 3 SD), pokud je SD větší než 1/3 průměru jsou teoreticky pravděpodobné záporné hodnoty v rozložení – ukazatel problémů s normalitou dat

Ukazatele tvaru rozložení

- ◆ **Skewness** – ukazatel „šikmosti“ rozložení, asymetrie rozložení
- ◆ **Kurtosis** – ukazatel „špičatosti/plochosti“ rozložení

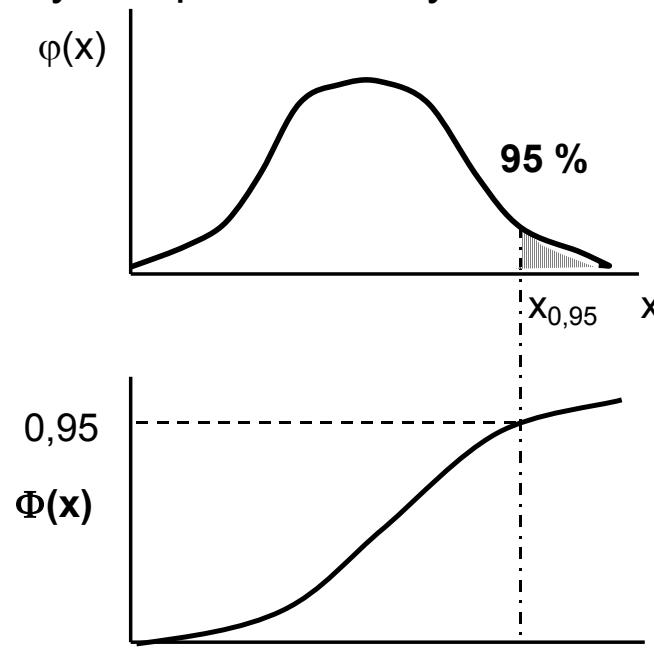


Další parametry rozložení

- ◆ **Počet hodnot** – důležitý ukazatel, znamená jak moc lze na data spoléhat
- ◆ **Střední chyba odhadu průměru** - je založena na směrodatné odchylce rozložení a **počtu hodnot**, vlastně jde o směrodatnou odchylku rozložení průměru. Říká jak přesný je náš výpočet průměru. Čím větší počet hodnot rozložení, tím je náš odhad skutečného průměru přesnější.
- ◆ **Suma hodnot**
- ◆ **Modus** – nejčastější hodnota, vhodný např. při kategoriálních datech
- ◆ **Minimum, maximum**
- ◆ **Rozsah hodnot**
- ◆ **Harmonický průměr** - převrácená hodnota průměru převrácených hodnot (vždy platí harmonický průměr < geometrický průměr < aritmetický průměr)

Distribuční funkce

- ◆ Definice kvantilu dle distribuční funkce - Kvantil rozložení ($X_{0,95}$) je číslo, jehož hodnota distribuční funkce je rovna pravděpodobnosti, pro kterou je kvantil definován ($\Phi(x)$... distribuční funkce), tj. pokud vezmeme nějaký bod rozložení a porovnáme jej s tímto bodem (kvantilem), máme 95% pravděpodobnost, že bude menší než hodnota kvantilu ($X_{0,95}$).
- ◆ Pomocí distribuční funkce můžeme určit jaký podíl hodnot rozložení je menší než daná hodnota – využití při statistických testech



Základní popisná statistika

Výběr proměnných

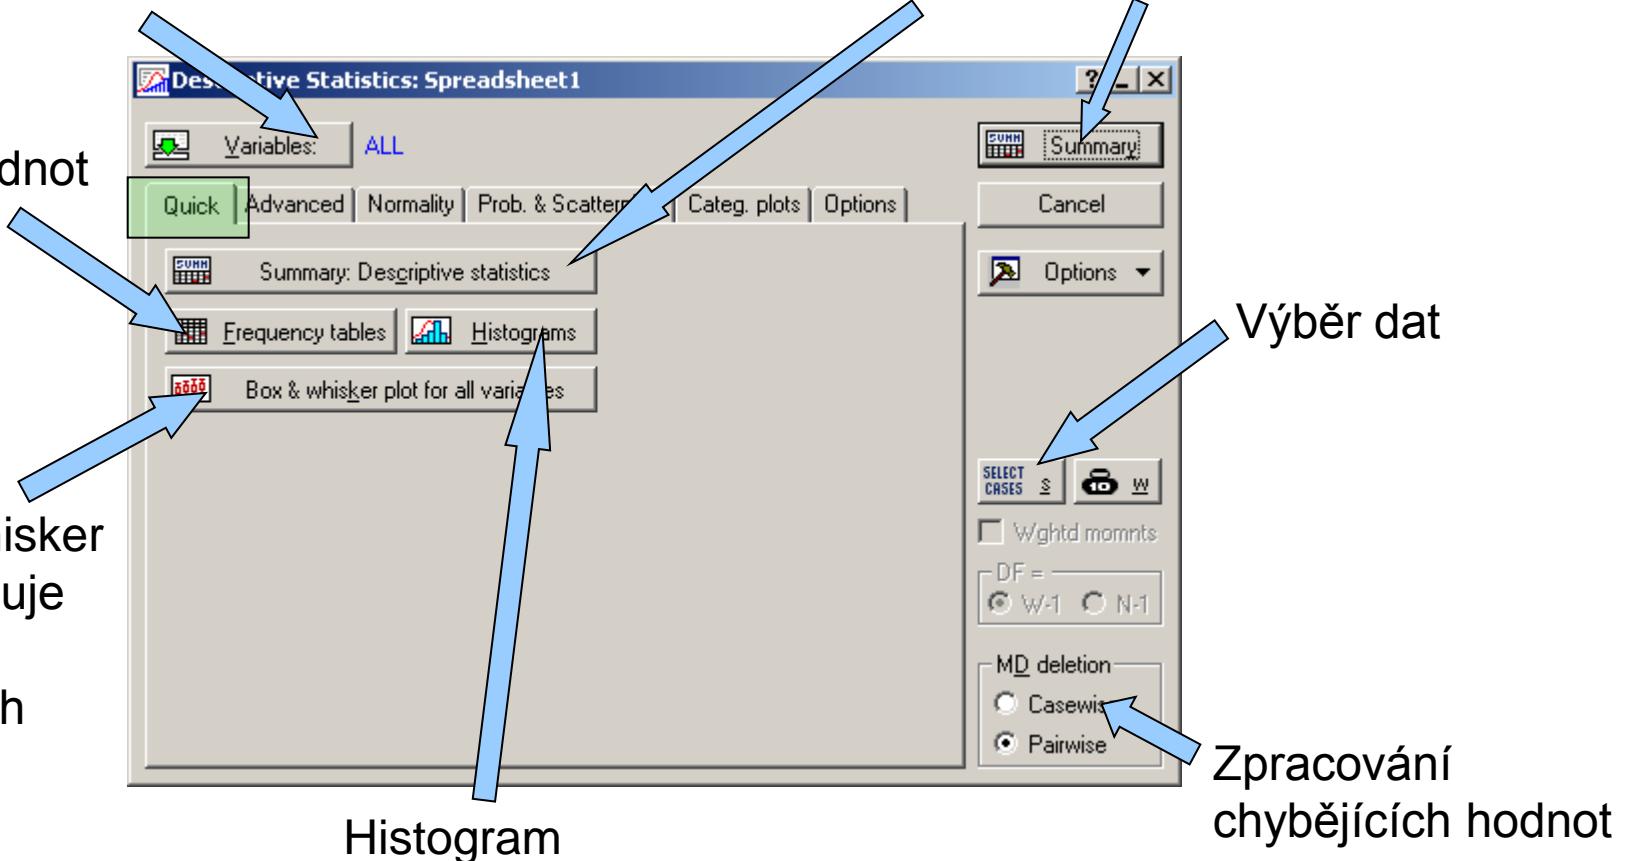
Tabulka
četností hodnot

Box and whisker
plot (následuje
nastavení
zobrazených
parametrů)

Základní výstup

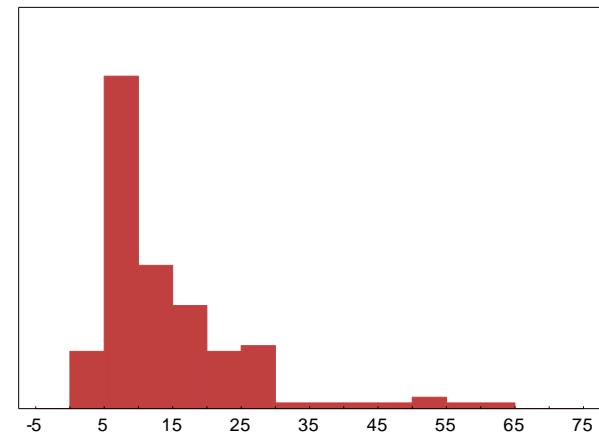
Výběr dat

Zpracování
chybějících hodnot

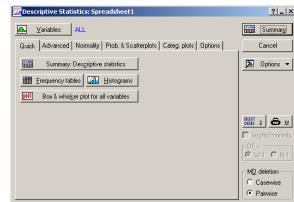


Popisné grafy I. Histogram a graf četnosti

- ◆ Tyto grafy se používají k zobrazení podílu výskytu hodnot v určitém intervalu proměnné. Oba grafy se liší způsobem zobrazení poměrů, zatímco sloupcový graf četností vynáší jako výšku sloupce přímo počet hodnot, u histogramu je důležitá plocha sloupce (počet hodnot zde odpovídá ploše a ne výšce sloupce), která vyjadřuje podíl objektů v daném intervalu, výška sloupce histogramu se získá jako podíl plochy (tj. počtu objektů) a šířky intervalu. V případě stejných šířek intervalů vypadají oba typy grafů stejně, liší se v případě nestejných intervalů (sloupce histogramu jsou u širších intervalů nižší – plocha sloupce odpovídá počtu objektů).
- ◆ Sloupce tedy odráží četnost objektů v daném intervalu, kterou vyjadřují buď svou výškou nebo plochou. Histogramy mohou existovat v několika formách 1) histogram relativních a absolutních četností a 2) histogram normální a kumulativní.



Analýza dat na PC I.



Tvorba grafů

- ◆ Jako součást analýzy
- ◆ Lišta grafů
- ◆ Samostatné menu grafů
- ◆ Graphs of block and input data

7 Var7 8 Var8 9 Var9 10 Var10

| | | | |
|-----------|--------------------------|------------------------|----------|
| 0,2398791 | 0,063452 | 0,288747 | 0,480281 |
| 0,4378 | Statistics of Block Data | 687158 | |
| 0,5741 | Graphs of Block Data | 295108 | |
| 0,7851 | Graphs of Input Data | Var7... | |
| 0,3251 | | Histogram Var7 | |
| 0,3448 | Cut | Box-Whisker Var7 | |
| 0,3197 | Copy | Probability Plot Var7 | |
| 0,8221 | | Scatterplot by... | |
| 0,0961 | | 2D Histogram by... | |
| 0,6648 | Paste | 3D Histogram by... | |
| | | Box-Whisker by... | |
| | | Probability Plot by... | |
| | | Matrix Scatterplot... | |

Context menu options:
Cut Ctrl+X
Copy Ctrl+C
Copy with Headers
Paste Ctrl+V
Paste Special...
Fill/Standardize Block
Clear
Format
Marking Cells

Graphs Tools Data Window Help

Resume... Ctrl+R

Add to Report ?

Histograms...
Scatterplots...
Means w/Error Plots...
Surface Plots...

2D Graphs

- 3D Sequential Graphs
- 3D XYZ Graphs
- Matrix Plots...
- Icon Plots...
- Categorized Graphs
- User-defined Graphs

Graphs of Block Data

Graphs of Input Data

Multiple Graph Layouts

Histograms...
Scatterplots...
Means w/Error Plots...
Box Plots...
Range Plots...
Scatter Icon Plots...
Scatter Image Plots...
Scatterplots w/Histograms...
Scatterplots w/Box Plots...
Normal Probability Plots...
Quantile-Quantile Plots...
Probability-Probability Plots...
Bar/Column Plots...
Line Plots (Variables)...
Line Plots (Case Profiles)...
Sequential/Stacked...
Pie Charts...
Missing/Range Data Plots...
Custom Function Plots...

Tvorba histogramu/grafu četnosti

Způsob zobrazení
více proměnných

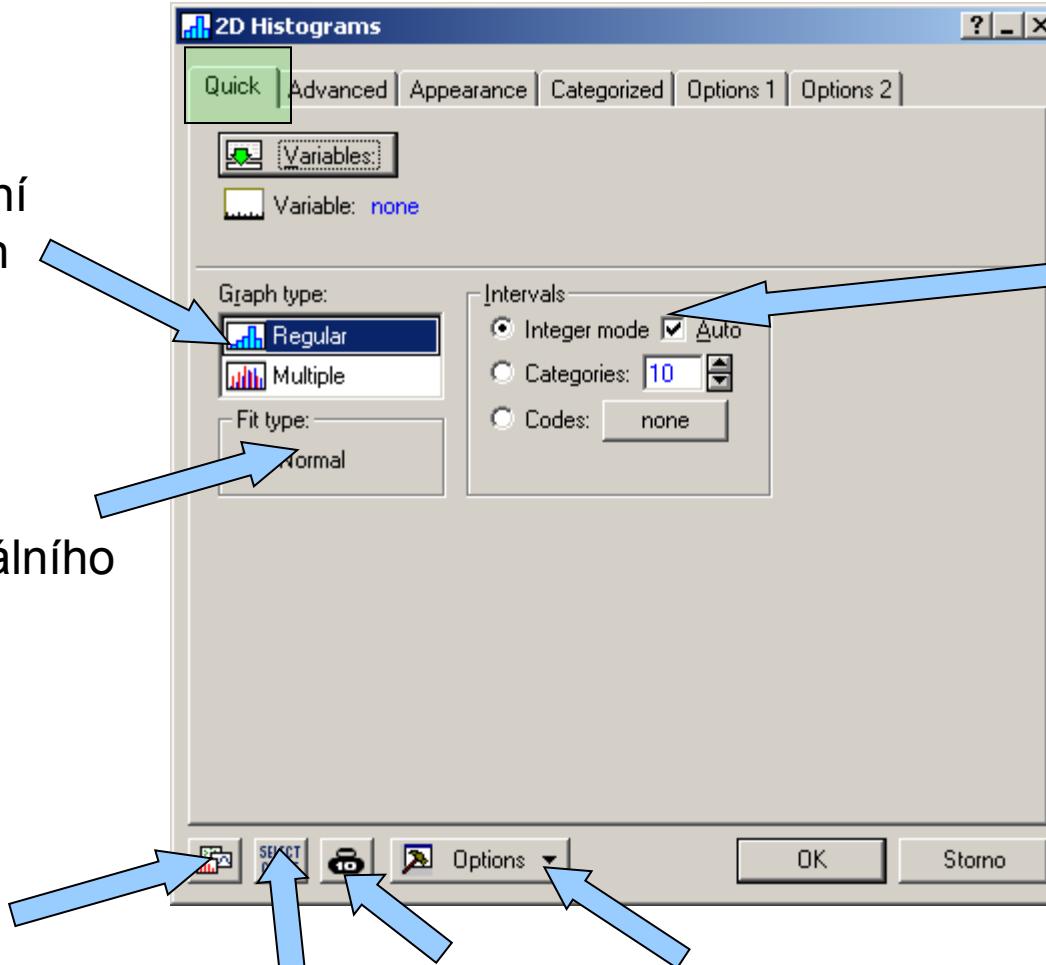
Proložení normálního
rozložení

Galerie všech grafů

Výběr dat

Vážení dat

Možnosti nastavení



Nastavení intervalů
grafu:

- Na základě celých
čísel v datech
- Počet intervalů
- Podle kódů

Pokročilá tvorba histogramu/grafu četnosti

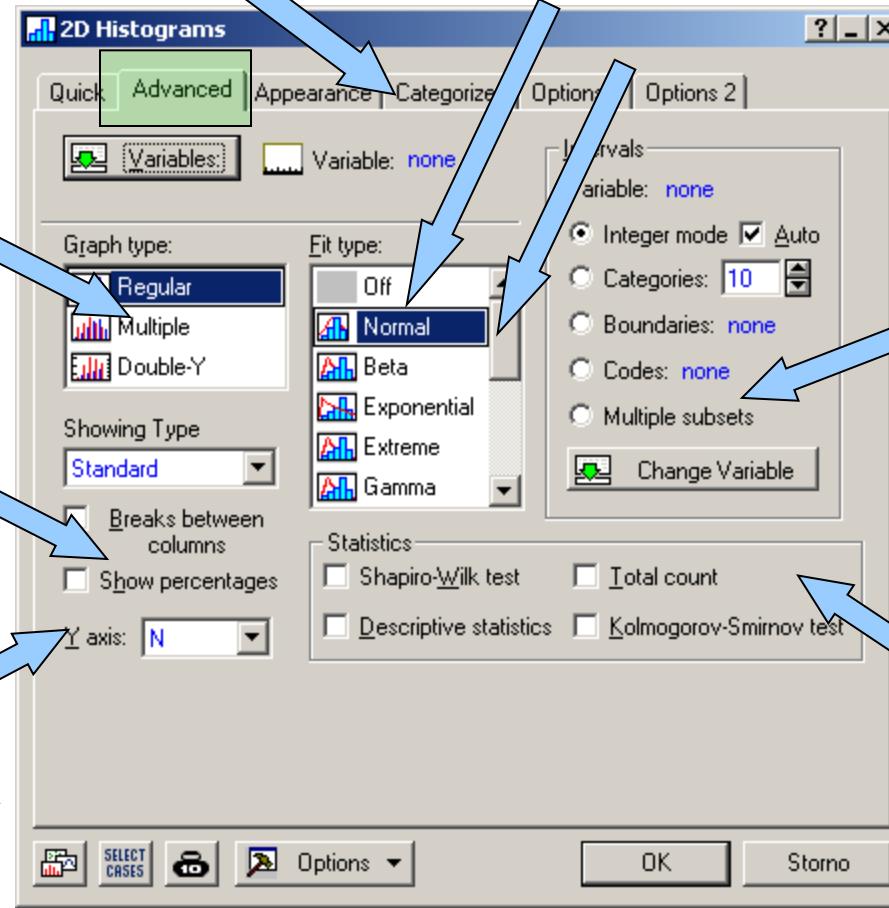
Kategorizace grafu

Proložení různých rozložení

Způsob zobrazení
více proměnných

Způsob zobrazení

Zobrazení hodnot na
ose Y



Kategorizace

- celá čísla v datech
- počet kategorií
- hranice
- kódy
- výběr dat

Testy normality a
popisná statistika

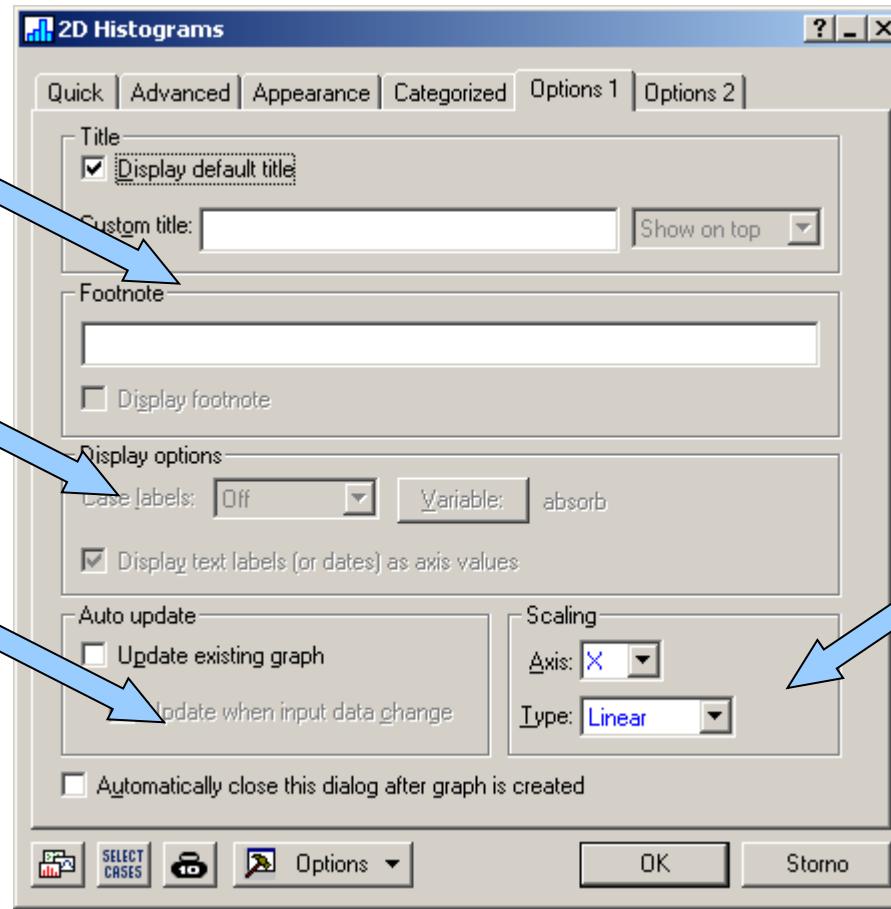
Nastavení společná různým typům grafů I

Popisky grafu

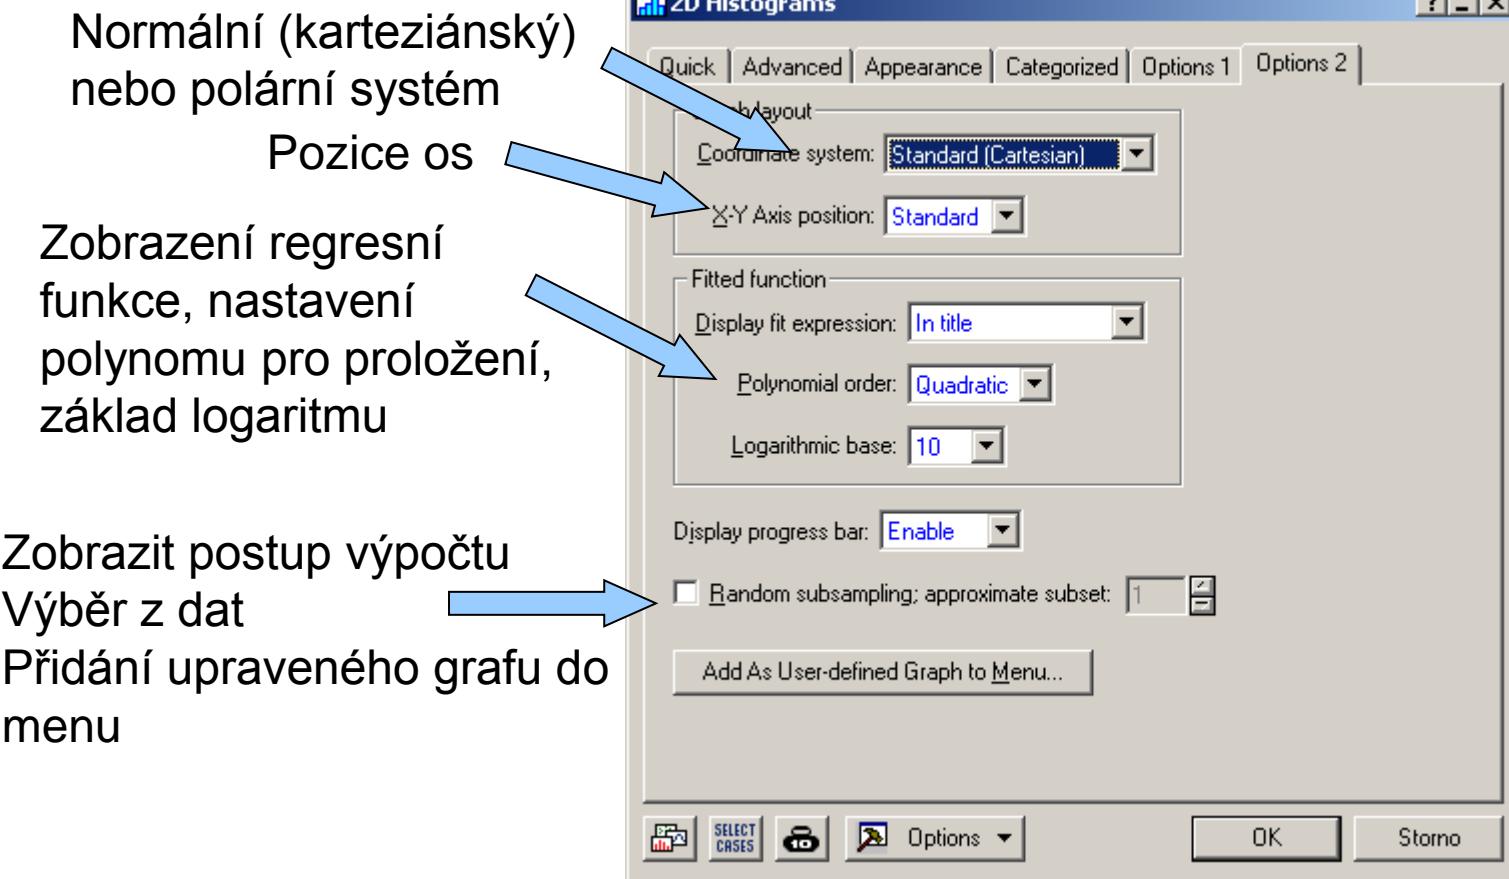
Zobrazení popisek
dat

Překreslení
existujícího grafu

Transformace os

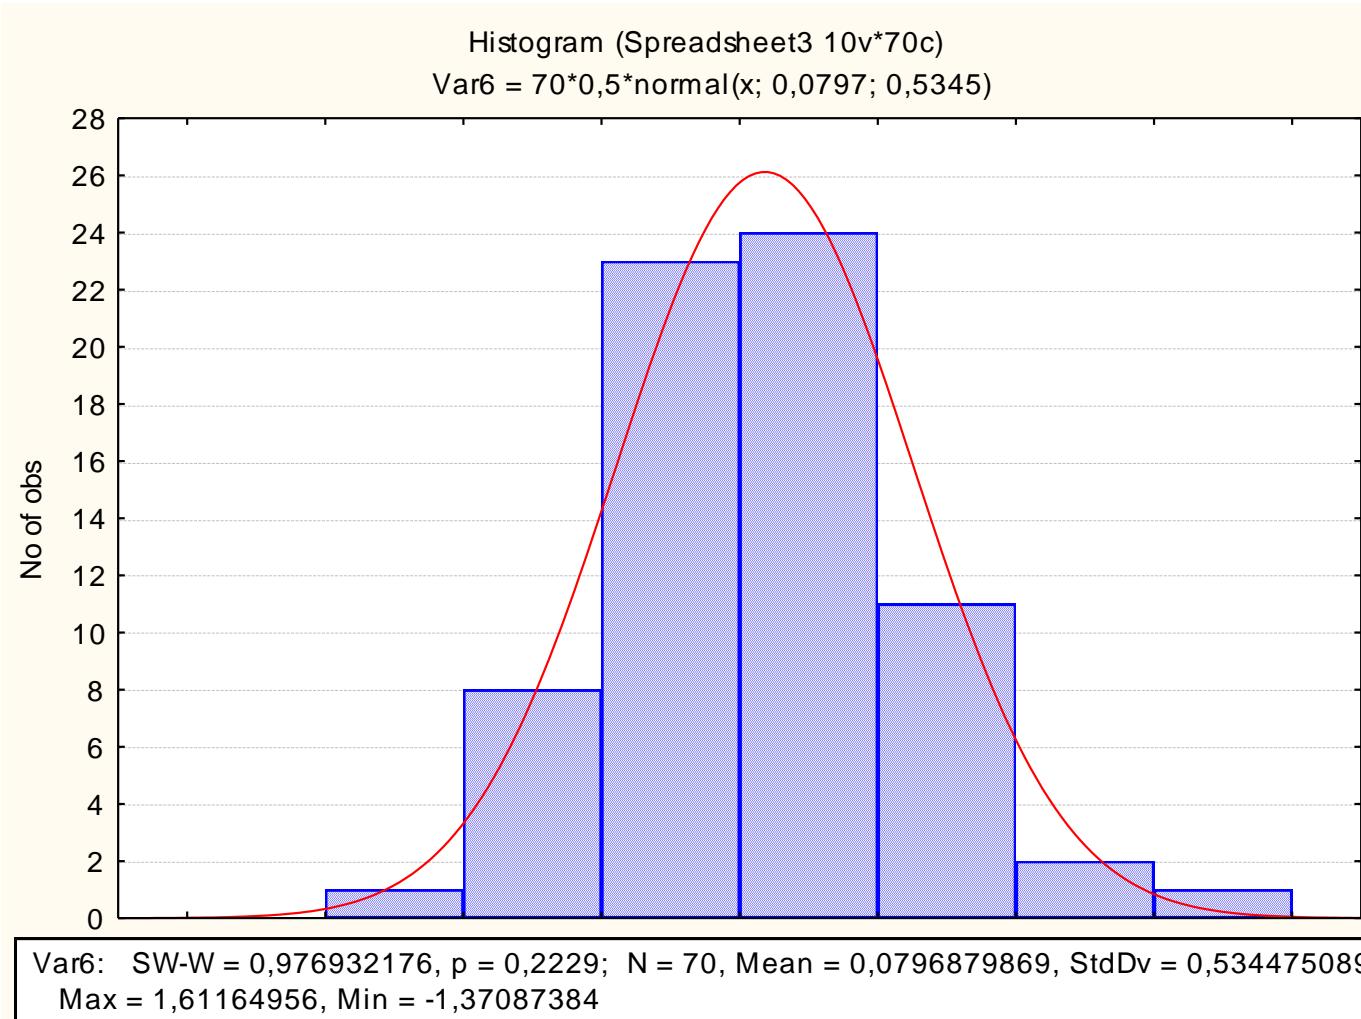


Nastavení společná různým typům grafů II



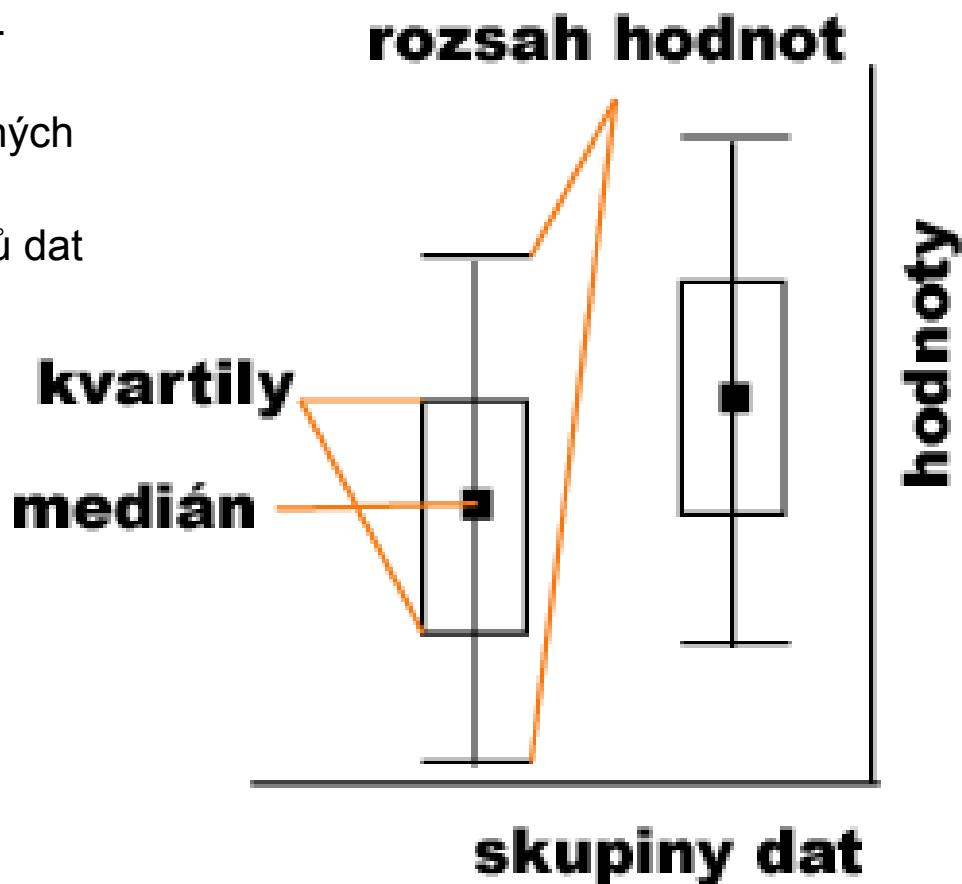
Analýza dat na PC I.

Ne - Histogram



Box & whisker plot

- ◆ Typ grafu vynášející několik význačných bodů rozložení, např. medián, kvartily a rozsah hodnot
- ◆ Poskytuje grafický přehled popisných statistik
- ◆ Rychlé srovnání několika souborů dat
- ◆ Umožňuje orientačně posoudit normalitu dat



Box and whisker plot

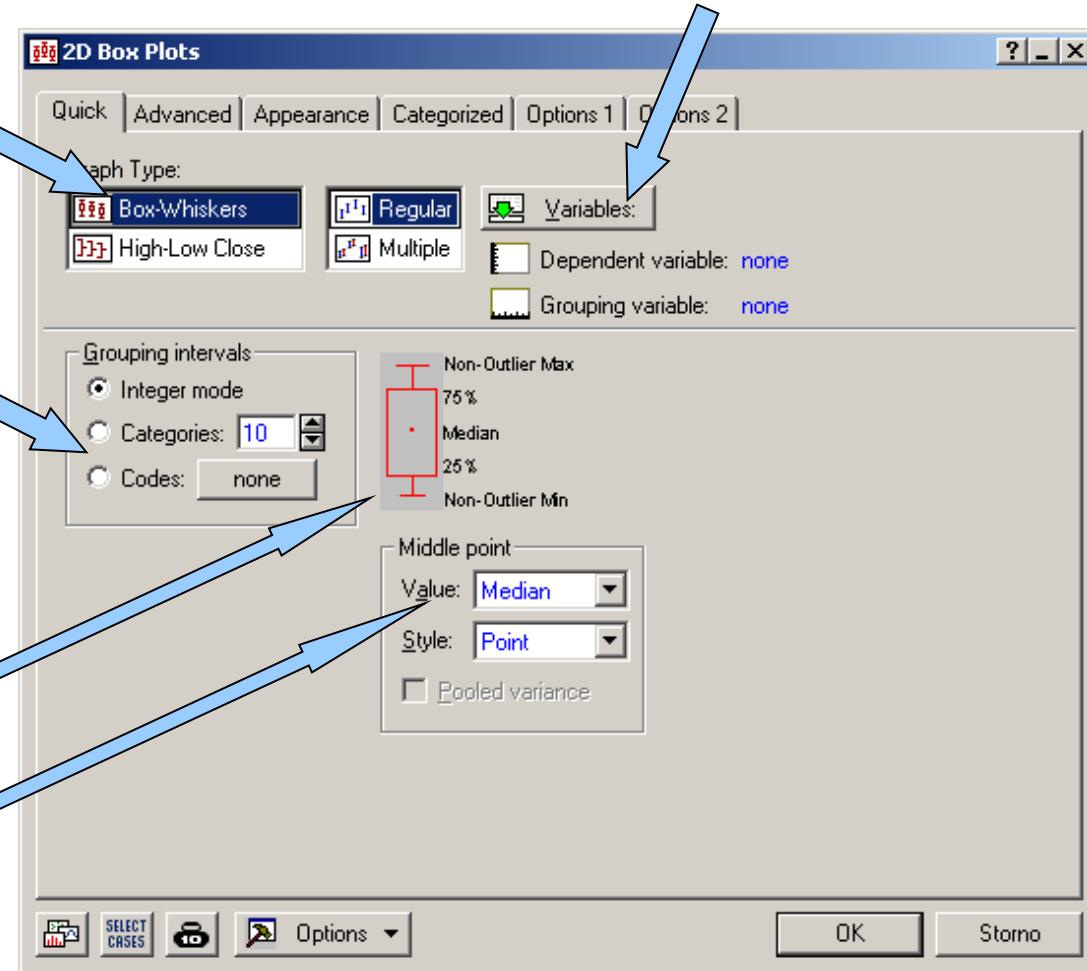
Datová a kategorizační proměnná

Způsob zobrazení box and whisker plotu

Kategorizace hodnot do jednotlivých grafů

Preview grafu

Ukazatel středu



Analýza dat na PC I.

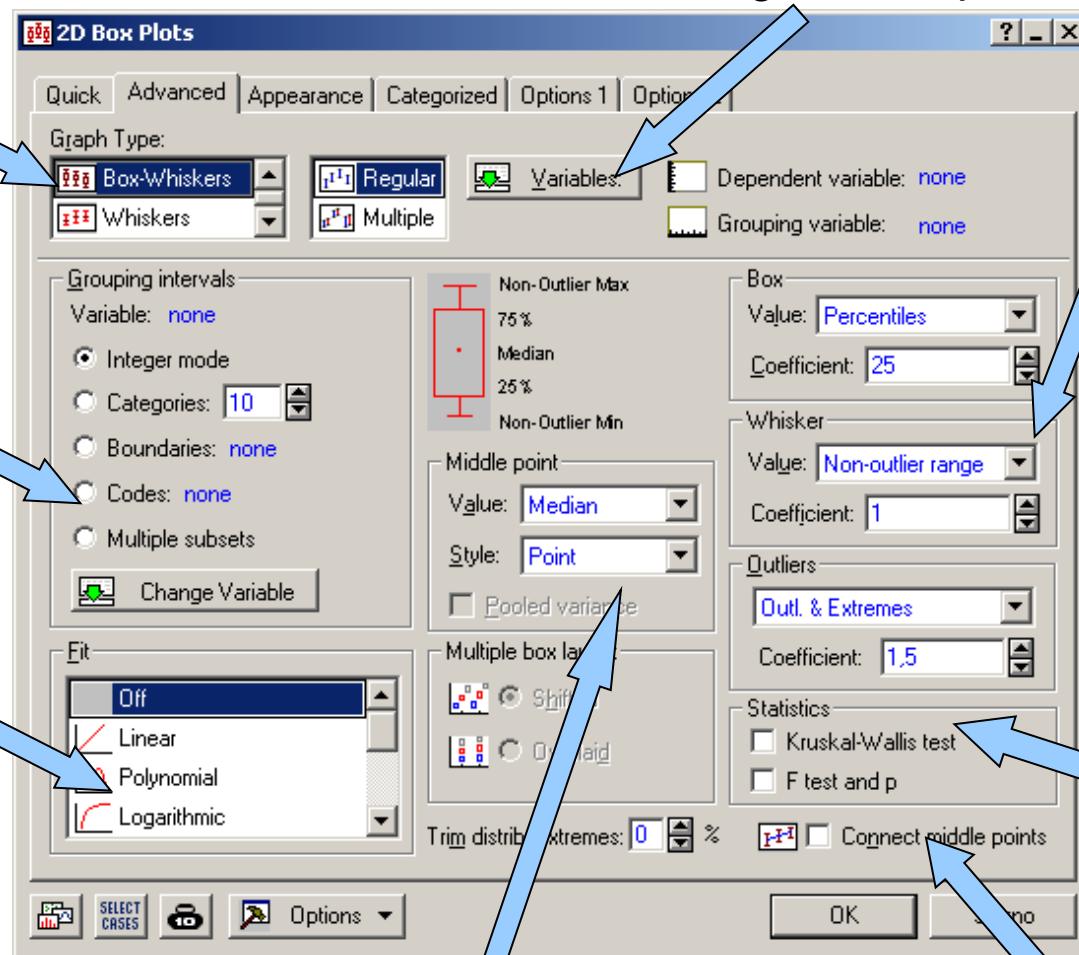
Box & whisker plot II

Datová a kategorizační proměnná

Typ grafu

Kategorizace hodnot
do jednotlivých grafů

Proložení křivky

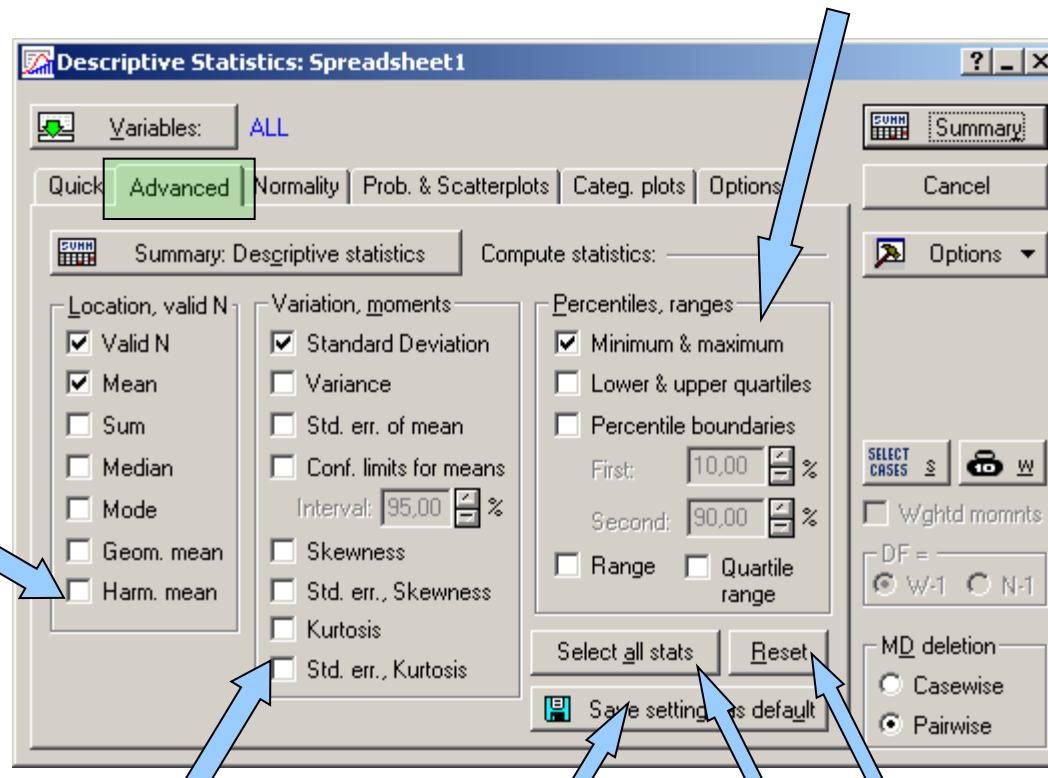


Které
statistiky
budou
zobrazeny

Statistické
testy

Detailní popisná statistika

Percentily, rozsahy



Ukazatele
středu rozložení
a počet hodnot

Tvar rozložení (šířka,
asymetrie atd.)

Uložení nastavení

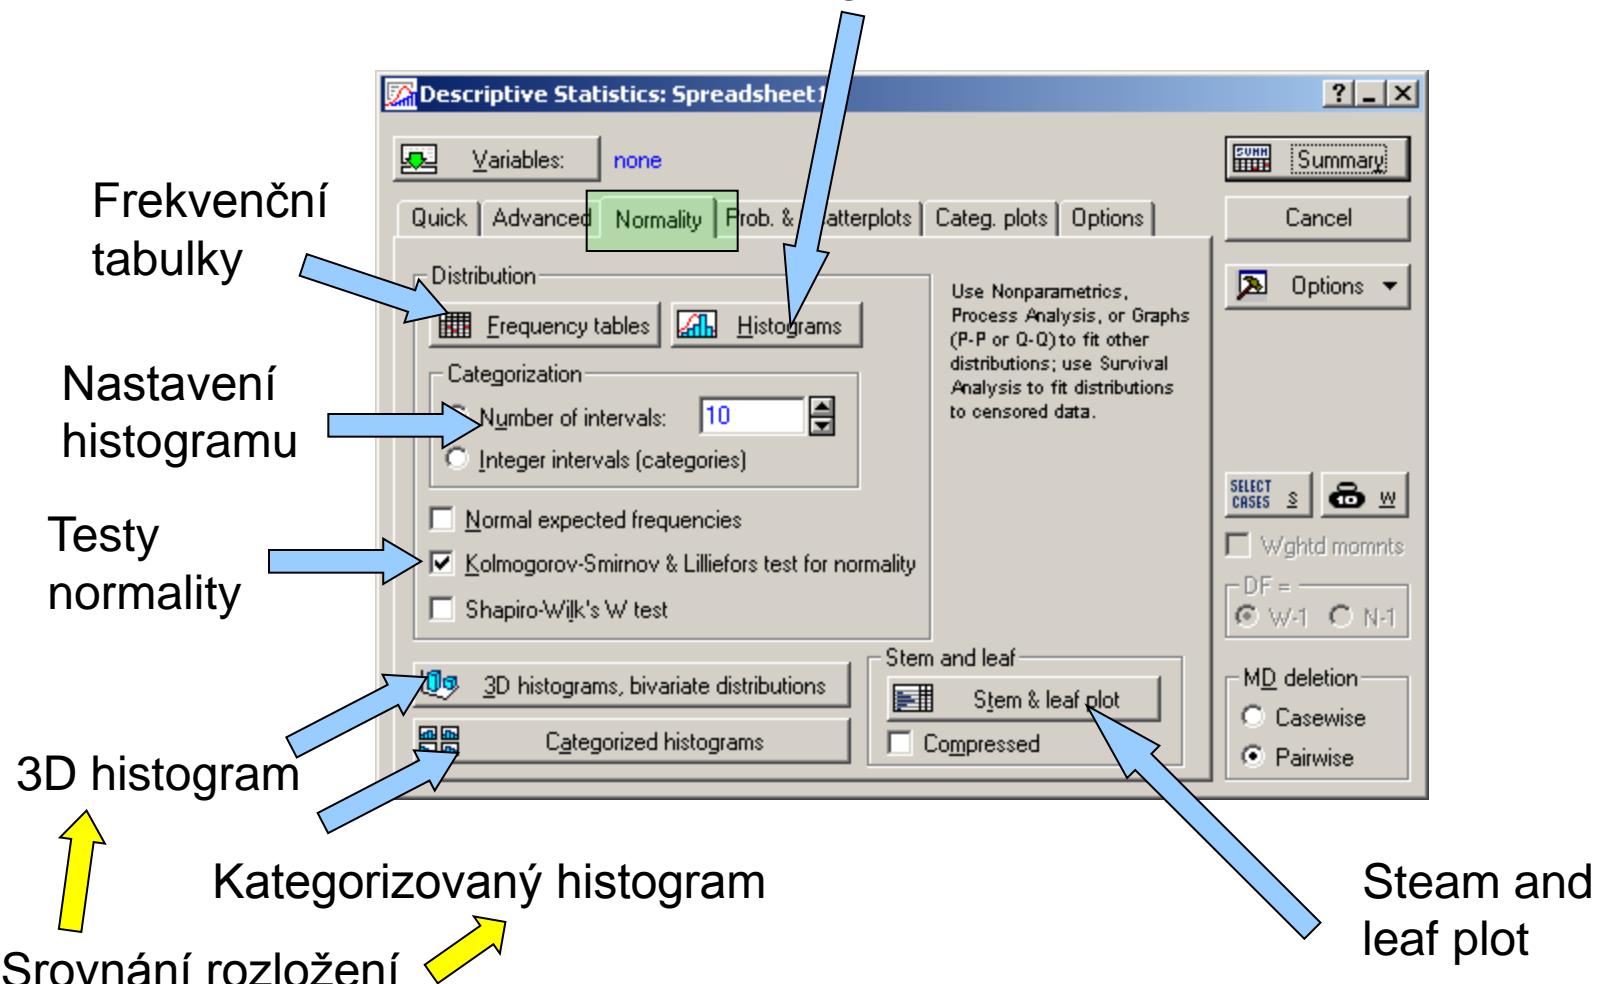
Zrušení výběru statistik

Vybrání všech statistik

Analýza dat na PC I.

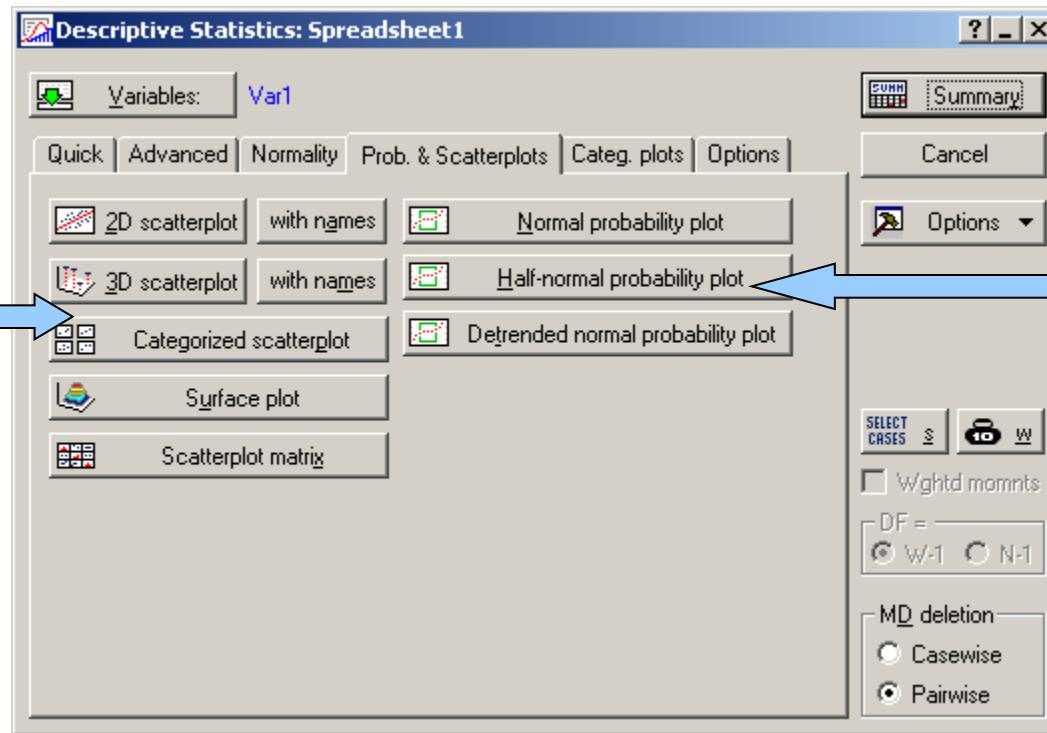
Normalita dat

Histogram



Popisné grafy

Grafy
vynášející proti
sobě různým
způsobem
proměnné

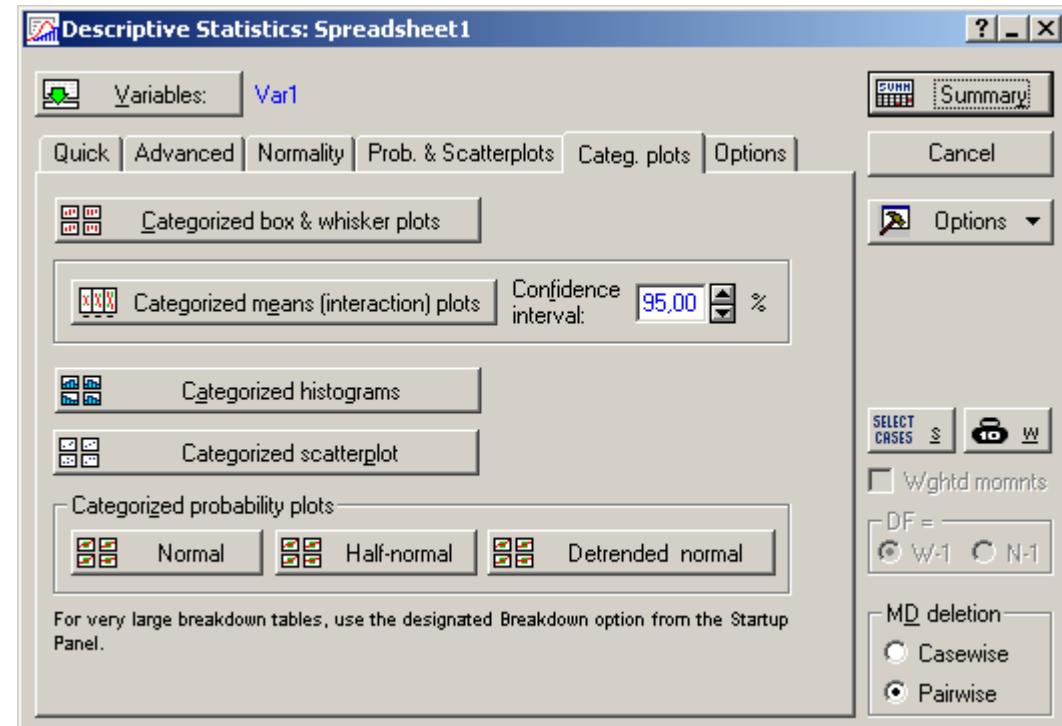


Grafy normality

Kategorizované grafy

Kategorizované grafy

proměnné jsou rozloženy na skupiny dané kategorizační proměnnou (např. proměnná obsahující výšku postavy může být rozdělena podle pohlaví jinou proměnnou obsahující informaci o pohlaví jednotlivých osob (řádků první proměnné)



Nastavení popisné statistiky

Obecná nastavení
Nastavení zobrazení box & whisker plotu

