

# 1. Průzkumová analýza jednorozměrných dat, diagnostické grafy

## Motivace

Průzkumová analýza dat je odvětví statistiky, které pomocí různých postupů odhaluje zvláštnosti v datech. Při zpracování dat se často používají metody, které jsou založeny na předpokladu, že data pocházejí z nějakého konkrétního rozložení, nejčastěji normálního. Tento předpoklad nemusí být vždy splněn, protože data

- mohou pocházet z jiného rozložení
- mohou být zatížena hrubými chybami
- mohou pocházet ze směsi několika rozložení.

Proto je důležité provést průzkumovou analýzu dat, abychom se vyvarovali neadekvátního použití statistických metod.

Data zkoumáme pomocí **funkcionálních** a **číselných charakteristik** a pomocí **diagnostických grafů**.

## Funkcionální charakteristiky datového souboru

### Označení

Na množině objektů  $\{\varepsilon_1, \dots, \varepsilon_n\}$  zjišťujeme hodnoty znaku X (např. u 6 domácností zjišťujeme počet členů).

Hodnotu znaku X na objektu  $\varepsilon_i$  označíme  $x_i$ ,  $i = 1, \dots, n$ .

Tyto hodnoty zaznamenáme do jednorozměrného datového souboru

$$\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \quad (\text{např. } \begin{pmatrix} 2 \\ 1 \\ 2 \\ 3 \\ 1 \\ 2 \end{pmatrix}).$$

Uspořádané hodnoty  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$  tvoří uspořádaný datový soubor

$$\begin{pmatrix} x_{(1)} \\ \vdots \\ x_{(n)} \end{pmatrix}, \quad (\text{v našem případě } \begin{pmatrix} 1 \\ 1 \\ 2 \\ 2 \\ 2 \\ 3 \end{pmatrix}).$$

Vektor  $\begin{pmatrix} x_{[1]} \\ \vdots \\ x_{[r]} \end{pmatrix}$ , kde  $x_{[1]} < \dots < x_{[r]}$  jsou navzájem různé hodnoty znaku X, se nazývá vektor variant, v našem případě  $\begin{pmatrix} 1 \\ 2 \\ 3 \end{pmatrix}$ .

## Bodové rozložení četností

Je-li počet variant znaku X malý, přiřazujeme četnosti jednotlivým variantám a hovoříme o bodovém rozložení četností.

$n_j$  – absolutní četnost varinty  $x_{[j]}$

$p_j = \frac{n_j}{n}$  – relativní četnost varinty  $x_{[j]}$

$N_j = n_1 + \dots + n_j$  – absolutní kumulativní četnost prvních  $j$  variant

$F_j = \frac{N_j}{n} = p_1 + \dots + p_j$  – relativní kumulativní četnost prvních  $j$  variant

Absolutní a relativní četnosti zapisujeme do tabulky rozložení četností nebo je znázorňujeme graficky např. pomocí sloupkového diagramu či polygonu četností.

Četnostní funkce:  $p(x) = \begin{cases} p_j & \text{pro } x = x_{[j]}, j = 1, \dots, r \\ 0 & \text{jinak} \end{cases}$

Empirická distribuční funkce:  $F(x) = \begin{cases} 0 & \text{pro } x < x_{[1]} \\ F_j & \text{pro } x_{[j]} \leq x < x_{[j+1]}, j = 1, \dots, r-1 \\ 1 & \text{pro } x \geq x_{[r]} \end{cases}$

**Příklad 1.:** U 30 domácností byl zjišťován počet členů.

Počet členů	1	2	3	4	5	6
Počet domácností	2	6	4	10	5	3

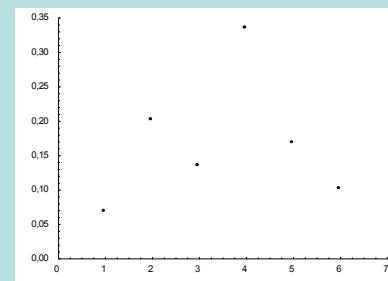
Vytvořte tabulku rozložení četností. Nakreslete grafy četnostní funkce a empirické distribuční funkce. Dále nakreslete sloupkový diagram a polygon četností počtu členů domácnosti.

**Řešení:**

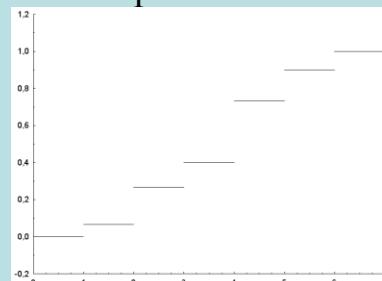
Tabulka rozložení četností

$x_{[j]}$	$n_j$	$p_j$	$N_j$	$F_j$
1	2	2/30	2	2/30
2	6	6/30	8	8/30
3	4	4/30	12	12/30
4	10	10/30	22	22/30
5	5	5/30	27	27/30
6	3	3/30	30	1

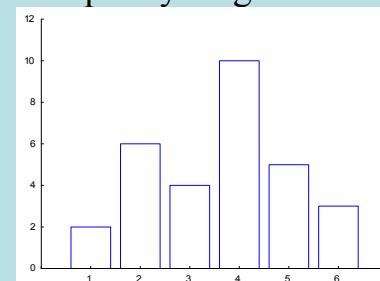
Graf četnostní funkce



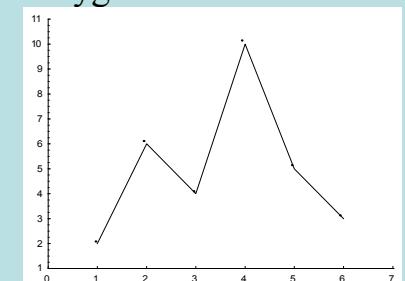
Graf empirické distribuční funkce



Sloupkový diagram



Polygon četností



## Intervalové rozložení četnosti

Je-li počet variant znaku X velký, přiřazujeme četnosti nikoli jednotlivým variantám, ale třídicím intervalům  $\langle u_1, u_2 \rangle, \dots, \langle u_r, u_{r+1} \rangle$  a hovoříme o intervalovém rozložení četností. Názvy četností jsou podobné jako u bodového rozložení četností, na- víc zavádíme **četnostní hustotu** j-tého třídicího intervalu  $f_j = \frac{p_j}{d_j}$ , kde  $d_j = u_{j+1} - u_j$ . Stanovení počtu třídicích intervalů je dosti subjektivní záležitost. Často se doporučuje volit r blízké  $\sqrt{n}$ .

**Hustota četnosti:**  $f(x) = \begin{cases} f_j & \text{pro } u_j < x \leq u_{j+1}, j = 1, \dots, r \\ 0 & \text{jinak} \end{cases}$  (grafem hustoty četnosti je histogram)

**Intervalová empirická distribuční funkce:**  $F(x) = \int_{-\infty}^x f(t)dt$ .

**Příklad 2.:** U 70 domácností byly zjišťovány týdenní výdaje na nealkoholické nápoje (v Kč).

Výdaje	$\langle 5, 65 \rangle$	$\langle 65, 95 \rangle$	$\langle 95, 125 \rangle$	$\langle 125, 155 \rangle$	$\langle 155, 185 \rangle$	$\langle 185, 215 \rangle$
Počet dom.	7	16	27	14	4	2

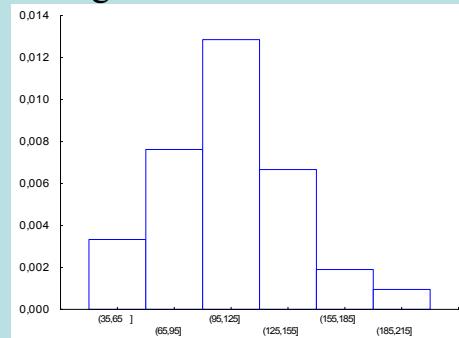
Sestavte tabulku rozložení četností, nakreslete histogram a graf intervalové empirické distribuční funkce.

**Řešení:**

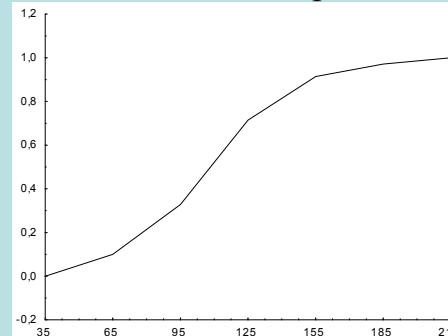
Tabulka rozložení četností

$(u_j, u_{j+1}]$	$n_j$	$p_j$	$f_j$	$N_j$	$F_j$
$\langle 5, 65 \rangle$	7	7/70	7/2100	7	7/70
$\langle 65, 95 \rangle$	16	16/70	16/2100	23	23/70
$\langle 95, 125 \rangle$	27	27/70	27/2100	50	50/70
$\langle 125, 155 \rangle$	14	14/70	14/2100	64	64/70
$\langle 155, 185 \rangle$	4	4/70	4/2100	68	68/70
$\langle 185, 215 \rangle$	2	2/70	2/2100	70	1

Histogram



Graf intervalové empirické distribuční funkce



## Číselné charakteristiky datového souboru

### Znaky nominálního typu

Tyto znaky umožňují obsahovou interpretaci pouze u relace rovnosti.

Příklady nominálních znaků: lékařská diagnóza, typ profese, barva očí, rodinný stav, národnost, ...

Charakteristikou polohy je **modus**, tj. nejčetnější varianta či střed nejčetnějšího intervalu.

### Znaky ordinálního typu

Lze u nich navíc obsahově interpretovat relaci uspořádání.

Příklad ordinálního znaku: školní klasifikace vyjadřuje menší nebo větší znalosti zkoušených žáků – jedničkář je lepší než dvojkař, ale intervaly mezi známkami nemají obsahovou interpretaci. Nelze tvrdit, že rozdíl ve znalostech mezi jedničkářem a dvojkařem je stejný jako mezi trojkařem a čtyřkařem.

Další příklady: Různá bodování ve sportovních a uměleckých soutěžích, posuzování různých rysů sociálního chování, posuzování stavu pacientů, hodnocení postojů respondentů k různým otázkám, ...

Charakteristikou polohy je  **$\alpha$ -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 výpočet  $\alpha$ -kvantilu slouží algoritmus:

$$n\alpha = \begin{cases} \text{celé číslo } c \Rightarrow x_\alpha = \frac{x_{(c)} + x_{(c+1)}}{2} \\ \text{necelé číslo} \Rightarrow \text{zaokrouhlíme nahoru na nejbližší celé číslo } c \Rightarrow x_\alpha = x_{(c)} \end{cases}$$

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**,  $x_{0,01}, \dots, x_{0,99}$  – **percentily**.

Jako charakteristika variability slouží **kvartilová odchylka**:  $q = x_{0,75} - x_{0,25}$ .

**Příklad 3.:** Během semestru se studenti podrobili písemnému testu z matematiky, v němž bylo možno získat 0 až 10 bodů. Výsledky jsou uvedeny v tabulce:

Počet bodů	0	1	2	3	4	5	6	7	8	9	10
Počet studentů	1	4	6	7	11	15	19	17	12	6	3

Zjistěte modus, medián, 1. decil, 9. decil a kvartilovou odchylku počtu bodů.

### Řešení:

Modus je nejčetnější varianta znaku, v tomto případě tedy 6.

Pro výpočet kvantilů musíme znát rozsah datového souboru:  $n = 1 + 4 + \dots + 3 = 101$ . Výpočty uspořádáme do tabulky.

$\alpha$	$n\alpha$	c	$x_{\alpha}=x_{(c)}$
0,50	50,5	51	6
0,10	10,1	11	2
0,90	90,9	91	8
0,25	25,25	26	4
0,75	75,75	76	7

$$q = 7 - 4 = 3$$

### Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o 2 proměnných a 11 případech. První proměnnou nazveme X, druhou cetnost a zapíšeme do nich počet bodů a odpovídající absolutní četnosti.

Statistiky – Základní statistiky/tabulky – Popisné statistiky – zapneme proměnnou vah cetnost – OK – OK – Proměnné X – OK – Detailní výsledky – vybereme Medián, Dolní a horní kvartily, Kvartilové hranice – Výpočet – ve výstupní tabulce upravíme počet desetinných míst.

Proměnná	Popisné statistiky (počet bodu.sta)					
	N platných	Medián	Spodní kvartil	Horní kvartil	Kvantil 10,00000	Kvantil 90,00000
X	101	6	4	7	2	8

## Znaky intervalového a poměrového typu

U těchto znaků lze navíc obsahově interpretovat operaci rozdílu resp. podílu.

Příklad intervalového znaku: teplota měřená ve stupních Celsia. Např. naměříme-li ve čtyřech po sobě jdoucích dnech poslední teploty 0, 2, 4, 6 °C, znamená to, že každým dnem stoupaly teploty o 2 °C. Nelze však říci, že z druhého na třetí den vzrostla teplota dvojnásobně, kdežto ze třetího na čtvrtý den pouze jeden a půl krát.

Další příklady: kalendářní systémy, směr větru, inteligenční kvocient, ...

Společný znak intervalových znaků: nula byla stanovena uměle, pouhou konvencí.

Příklad poměrového znaku: délka předmětu měřená v cm. Má-li jeden předmět délku 8 cm a druhý 16 cm, má smysl prohlásit, že druhý předmět je dvakrát delší než první předmět.

Další příklady: počet dětí v rodině, výška kapesného v Kč, hmotnost osoby, ...

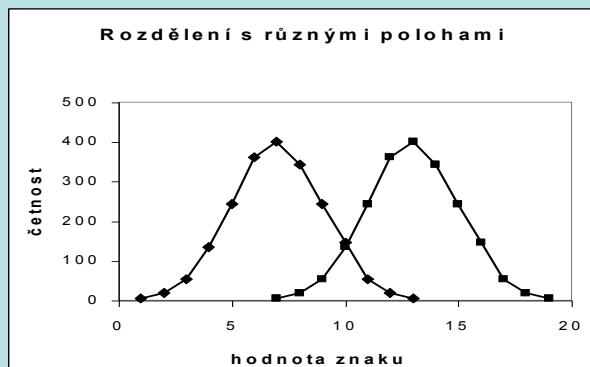
Společný znak poměrových znaků: poměrový znak má přirozený počátek, ke kterému jsou vztahovány všechny další hodnoty znaku.

Charakteristika polohy: **aritmetický průměr**  $m = \frac{1}{n} \sum_{i=1}^n x_i$ .

U poměrových znaků, které nabývají pouze kladných hodnot, lze použít **geometrický průměr**  $\sqrt[n]{x_1 \cdot \dots \cdot x_n}$ .

Pomocí průměru zavedeme **i-tou centrovanou hodnotu**  $x_i - m$  (podle znaménka poznáme, zda i-tá hodnota je podprůměrná či nadprůměrná).

Znázornění rozložení četnosti dvou datových souborů, které se liší aritmetickým průměrem



## Vlastnosti aritmetického průměru

- Aritmetický průměr si lze představit jako těžiště dat – součet podprůměrných hodnot je stejný jako součet nadprůměrných hodnot – oba součty jsou v rovnováze.
- Průměr centrovaných hodnot je nulový, protože  $\frac{1}{n} \sum_{i=1}^n (x_i - m) = \frac{1}{n} \sum_{i=1}^n x_i - \frac{1}{n} \sum_{i=1}^n m = m - \frac{1}{n} \cdot n \cdot m = 0$ .
- Výraz  $\sum_{i=1}^n (x_i - a)^2$  (tzv. kvadratická odchylka) nabývá svého minima pro  $a = m$ . Uvedený výraz charakterizuje celkovou chybu, které se dopustíme, když datový soubor nahradíme jedinou hodnotou  $a$ . Tato chyba je tedy nejmenší, když datový soubor nahradíme aritmetickým průměrem, přičemž za míru chyby považujeme kvadratickou odchylku.
- Pokud každou hodnotu  $x_i$  podrobíme lineární transformaci  $y_i = a + bx_i$ , pak průměr transformovaných hodnot je roven lineární transformaci původního průměru, tj.  $m_2 = a + bm_1$ .
- Mají-li znaky  $X, Y$  průměry  $m_1, m_2$ , pak znak  $Z = X + Y$  má průměr  $m_1 + m_2$ .
- Aritmetický průměr je silně ovlivněn extrémními hodnotami.
- Aritmetický průměr je vhodné použít, pokud je rozložení dat přibližně symetrické.

### **Příklad na vlastnosti aritmetického průměru:**

U skupiny 20 pracovníků v určité dílně byly zjištovány měsíční mzdy. Průměr mezd činil 15 500 Kč. Určete průměr mezd, jestliže mzdy všech pracovníků se zvýší

- a) o 300 Kč, b) 1,1 krát, c) o 20%.

### **Řešení:**

Označme  $m_1$  průměr hodnot  $x_1, \dots, x_n$  a  $m_2$  průměr hodnot  $y_1, \dots, y_n$ , přičemž  $y_i = a + bx_i$ ,  $i = 1, \dots, n$ . Pak  $m_2 = a + bm_1$ .

ad a)  $m_2 = 300 + m_1 = 15\ 800$

Průměr se zvýšil o 300 Kč na 15 800 Kč.

ad b)  $m_2 = 1,1 \cdot m_1 = 17\ 050$

Průměr se zvýšil na 17 050 Kč.

ad c)  $m_2 = 1,2 \cdot m_1 = 18\ 600$

Průměr se zvýšil na 18 600 Kč.

## Charakteristiky variability intervalových a poměrových znaků

Variační rozpětí  $R = x_{(n)} - x_{(1)}$  (nevýhoda – bere v úvahu pouze nejmenší a největší hodnotu datového souboru),

průměrná odchylka  $\sigma = \frac{1}{n} \sum_{i=1}^n |x_i - m|$  (udává, o kolik jednotek se data liší od průměru)

rozptyl  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$  (nevýhoda – vychází ve druhých mocninách jednotek, v nichž byl měřen znak X)

směrodatná odchylka  $s = \sqrt{s^2}$ .

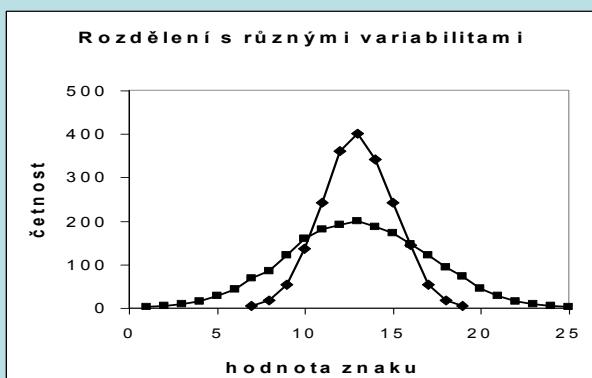
Pomocí směrodatné odchylky zavedeme i-tou standardizovanou hodnotu  $\frac{x_i - m}{s}$  (vyjadřuje, o kolik směrodatných odchylek se i-tá hodnota odchylila od průměru).

U poměrových znaků se jako charakteristika variability používá též:

koeficient variace  $\frac{s}{m}$  (často se udává v procentech a udává, kolika procent průměru dosahuje směrodatná odchylka),

relativní průměrná odchylka  $\frac{\sigma}{m}$  (při vyjádření v procentech udává, kolika procent průměru dosahuje průměrná odchylka)

Znázornění rozložení četností dvou datových souborů, které se liší rozptylem:



## Vlastnosti rozptylu:

- Rozptyl je nulový pouze tehdy, když jsou všechny hodnoty stejné, jinak je kladný.
- Rozptyl centrovaných hodnot je roven původnímu rozptylu, neboť  $\frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = s^2$ .
- Rozptyl standardizovaných hodnot je 1, protože  $\frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - m}{s} - 0 \right)^2 = \frac{1}{s^2} \cdot \frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \frac{s^2}{s^2} = 1$ .
- Rozptyl se zpravidla počítá podle vzorce  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$ .
- Pokud každou hodnotu  $x_i$  podrobíme lineární transformaci  $y_i = a + bx_i$ , pak rozptyl transformovaných hodnot je roven původnímu rozptylu vynásobenému  $b^2$ , tj.  $s_2^2 = b^2 s_1^2$ .
- Rozptyl je stejně jako průměr silně ovlivněn extrémními hodnotami.
- Rozptyl se nehodí jako charakteristika variability, je-li rozložení dat nesymetrické.

**Příklad 4.:** Kurzy akcií společnosti AAA Auto Group v průběhu 23 dní v měsíci srpnu 2010 byly následující: 17,75; 17,74; 17,85; 17,59; 17,92; 17,98; 18,39; 18,25; 18,30; 18,00; 18,15; 18,15; 18,22; 18,40; 18,25; 17,95; 18,25; 18,23; 17,95; 17,90; 17,80; 17,87; 17,87. Vypočtěte charakteristiky variability.

### Řešení:

Nejprve vypočítáme variační rozpětí:  $R = x_{\max} - x_{\min} = 18,4 - 17,59 = 0,81$ .

Před výpočtem dalších charakteristik variability musíme získat aritmetický průměr:  $m = \frac{1}{23} (17,75 + 17,74 + \dots + 17,87) = 18,033$ .

$$\text{Průměrná odchylka: } o = \frac{1}{n} \sum_{i=1}^n |x_i - m| = \frac{1}{23} (|17,75 - 18,033| + |17,74 - 18,033| + \dots + |17,87 - 18,033|) = 0,1965$$

$$\text{Relativní průměrná odchylka: } \frac{o}{m} \cdot 100\% = \frac{0,1965}{18,033} \cdot 100\% = 1,09\%$$

$$\text{Rozptyl: } s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \frac{1}{23} (17,75^2 + 17,74^2 + \dots + 17,87^2) - 18,033^2 = 0,049$$

$$\text{Směrodatná odchylka: } s = \sqrt{s^2} = \sqrt{0,049} = 0,2213$$

$$\text{Koeficient variace: } \frac{s}{m} \cdot 100\% = \frac{0,2213}{18,033} \cdot 100\% = 1,23\%$$

## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o jedné proměnné X a 23 případech. Do proměnné X zapíšeme zjištěné kurzy akcií. Statistiky – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné X – OK – Detailní výsledky – vybereme Průměr, Rozptyl, Rozpětí – Výpočet. Ve výstupní tabulce přidáme za proměnnou Rozptyl tři nové proměnné nazvané rozptyl, směr. odch. a koef. variace. Do Dlouhého jména proměnné rozptyl napíšeme  $=v3^2/23$ , Dlouhého jména proměnné směr. odch. napíšeme  $=sqrt(v4)$  a do Dlouhého jména proměnné koef. variace napíšeme  $=100*v5/v1$ .

Proměnná	Průměr	Rozpětí	Rozptyl	rozptyl $=v3^2/23$	směr. odch. $=sqrt(v4)$	koef. variace $=100*v5/v1$
x	18,03304	0,810000	0,051231	0,049004	0,221367976	1,22756858

Pro výpočet průměrné odchylky a relativní průměrné odchylky je zapotřebí přidat k původnímu datovému souboru dvě nové proměnné nazvané Průměr a Odchylka. Do Dlouhého jména proměnné Průměr napíšeme  $=18,033$  a do Dlouhého jména proměnné Odchylka napíšeme  $=abs(v1-v2)$ . Nyní spočteme průměr proměnné Odchylka: Statistiky – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné Odchylka – OK – Detailní výsledky – vybereme Průměr – Výpočet. Ve výstupní tabulce přejmenujeme proměnnou Průměr na prům. odch. a za tuto proměnnou přidáme proměnnou rel. prům. odch. Do jejího Dlouhého jména napíšeme  $=100*v1/18,033$ .

Proměnná	odchylka	rel. prům. odch. $=100*v1/18,033$
Odchylka	0,196478	1,08954839

## Vážené číselné charakteristiky

Známe-li absolutní četnosti  $n_1, \dots, n_r$  či relativní četnosti  $p_1, \dots, p_r$  variant  $x_{[1]}, \dots, x_{[r]}$ , můžeme spočítat

vážený průměr  $m = \frac{1}{n} \sum_{j=1}^r n_j x_{[j]} = \sum_{j=1}^r p_j x_{[j]}$ ,

vážený rozptyl  $s^2 = \frac{1}{n} \sum_{j=1}^r n_j (x_{[j]} - m)^2 = \sum_{j=1}^r p_j (x_{[j]} - m)^2$  (výpočetní vzorec:  $s^2 = \frac{1}{n} \sum_{j=1}^r n_j x_{[j]}^2 - m^2 = \sum_{j=1}^r p_j x_{[j]}^2 - m^2$ ),

váženou průměrnou odchylku  $\sigma = \sqrt{\frac{1}{n} \sum_{j=1}^r n_j |x_{[j]} - m|} = \sqrt{\sum_{j=1}^r p_j |x_{[j]} - m|}$ .

**Příklad 5.:** U 35 zaměstnanců byl zjištěn počet odpracovaných hodin za měsíc.

Počet odpracovaných hodin	184	185	186	187	188	189
Počet zaměstnanců	4	6	7	6	7	5

Vypočtěte průměr, průměrnou odchylku, relativní průměrnou odchylku, směrodatnou odchylku a koeficient variace počtu odpracovaných hodin.

**Řešení:**

$$\text{Vážený průměr: } m = \frac{1}{n} \sum_{j=1}^n x_{[j]} = \frac{1}{35} (4 \cdot 184 + 6 \cdot 185 + 7 \cdot 186 + 5 \cdot 187 + 7 \cdot 188 + 5 \cdot 189) = 186,6$$

Vážená průměrná odchylka:

$$o = \frac{1}{n} \sum_{j=1}^n |x_{[j]} - m| = \frac{1}{35} (4 \cdot |184 - 186,6| + 6 \cdot |185 - 186,6| + 7 \cdot |186 - 186,6| + 5 \cdot |187 - 186,6| + 7 \cdot |188 - 186,6| + 5 \cdot |189 - 186,6|) = 1,38 \text{ h} = 1 \text{h } 23 \text{ min}$$

min

$$\text{Vážený rozptyl: } s^2 = \frac{1}{n} \sum_{j=1}^n x_{[j]}^2 - m^2 = \frac{1}{35} (4 \cdot 184^2 + 5 \cdot 185^2 + 7 \cdot 186^2 + 5 \cdot 187^2 + 7 \cdot 188^2 + 5 \cdot 189^2) - 186,6^2 = 2,5257$$

$$\text{Vážená směrodatná odchylka: } s = \sqrt{s^2} = \sqrt{2,5257} = 1,59 \text{ h} = 1 \text{h } 35 \text{ min}$$

$$\text{Relativní průměrná odchylka: } \frac{o}{m} \cdot 100\% = \frac{1,38}{186,6} \cdot 100\% = 0,74\%$$

$$\text{Koeficient variace: } \frac{s}{m} \cdot 100\% = \frac{1,59}{186,6} \cdot 100\% = 0,85\%$$

Vidíme, že zaměstnanci odpracovali za měsíc v průměru 186,6 h, přičemž průměrná odchylka dosahuje 0,74 % průměrné odpracované doby a směrodatná odchylka dosahuje 0,85 % průměrné odpracované doby.

## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o 2 proměnných a 6 případech. První proměnnou nazveme X, druhou četnost a zapíšeme do nich počet odpracovaných hodin a odpovídající počty zaměstnanců.

Statistiky – Základní statistiky/tabulky – Popisné statistiky – zapneme proměnnou vah četnost – OK – OK – Proměnné X – OK – Detailní výsledky – vybereme Průměr, Rozptyl – Výpočet. Ve výstupní tabulce přidáme za proměnnou Rozptyl dvě nové proměnné nazvané směr. odch. a koef. variace. Do Dlouhého jména proměnné směr. odch. napíšeme =sqrt(v2\*34/35) a do Dlouhého jména proměnné koef. variace napíšeme =100\*v3/v1.

Proměnná	Průměr	Rozptyl	směr. odch. =sqrt(v2*34/35)	koef. variace =100*v3/v1
X	186,6	2,6	1,5892496	0,851687888

Pro výpočet průměrné odchylky a relativní průměrné odchylky je zapotřebí přidat k původnímu datovému souboru dvě nové proměnné nazvané Průměr a Odchylka. Do Dlouhého jména proměnné Průměr napíšeme =186,6 a do Dlouhého jména proměnné Odchylka napíšeme =abs(v1-v3). Nyní spočteme průměr proměnné Odchylka: Statistiky – Základní statistiky/tabulky – Popisné statistiky – zapneme proměnnou vah četnost – OK – OK – Proměnné Odchylka – OK – Detailní výsledky – vybereme Průměr – Výpočet. Ve výstupní tabulce přejmenujeme proměnnou Průměr na prům. odch. a za tuto proměnnou přidáme proměnnou rel. prům. odch. Do jejího Dlouhého jména napíšeme =100\*v1/186,6.

Proměnná	prům. odch.	rel. prům. odch. =100*v1/186,6
Odchylka	1,382857	0,741080998

Převod desetinných částí hodiny na minuty můžeme provést např. pomocí aplikace na adrese <http://www.prevody-jednotek.cz/>.

## Počáteční a centrální momenty

Aritmetický průměr a rozptyl jsou speciální případy momentů. Zavedeme

k-tý počáteční moment  $m_k = \frac{1}{n} \sum_{i=1}^n x_i^k$ ,  $k = 1, 2, \dots$ ,

k-tý centrální moment

$m_k = \frac{1}{n} \sum_{i=1}^n x_i - m \overline{x}^k$ ,  $k = 1, 2, \dots$

Pomocí 3. a 4. počátečního momentu se definuje šikmost a špičatost.

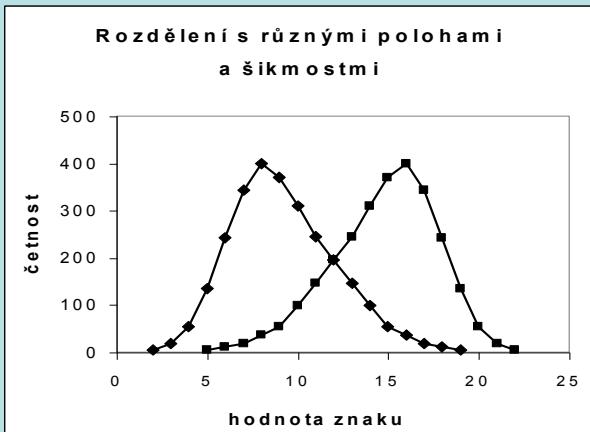
**Šikmost:**  $\alpha_3 = \frac{m_3}{s^3}$  - měří nesouměrnost rozložení četností kolem průměru.

Je-li rozložení dat symetrické kolem aritmetického průměru, pak  $\alpha_3 = 0$ .

Má-li rozložení dat prodloužený pravý konec, jde o **kladně zešikmené rozložení**,  $\alpha_3 > 0$ .

Má-li rozložení dar prodloužený levý konec, jde o **záporně zešikmené rozložení**,  $\alpha_3 < 0$ .

Znázornění rozložení četností dvou datových souborů, které se liší aritmetickým průměrem a šikmostí



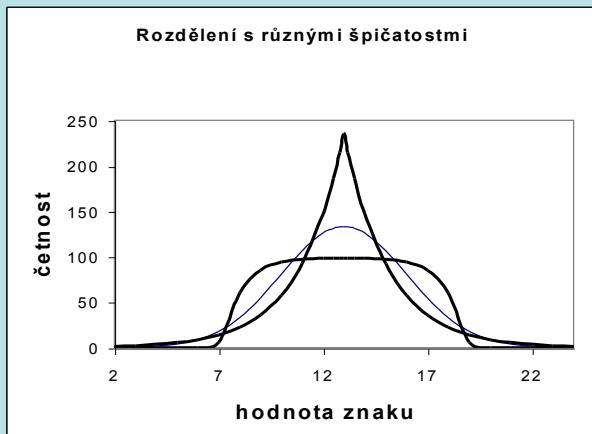
**Špičatost:**  $\alpha_4 = \frac{m_4}{s^4} - 3$  - měří koncentraci rozložení četností kolem průměru.

Je-li rozložení dat normální (Gaussovo), pak  $\alpha_4 = 0$ .

Je-li rozložení dat strmé, pak  $\alpha_4 > 0$ .

Je-li rozložení dat ploché, pak  $\alpha_4 < 0$ .

Znázornění rozložení četností dvou datových souborů, které se liší špičatostí

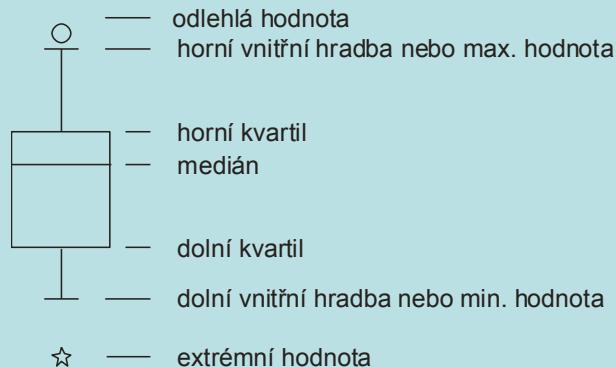


## Diagnostické grafy

### Krabicový diagram

Umožňuje posoudit symetrii a variabilitu datového souboru a existenci odlehlých či extrémních hodnot.

Způsob konstrukce



**Odlehlá hodnota** leží mezi **vnějšími a vnitřními hradbami**, tj. v intervalu

$(x_{0,75} + 1,5q, x_{0,75} + 3q)$  či v intervalu  $(x_{0,25} - 3q, x_{0,25} - 1,5q)$ .

**Extrémní hodnota** leží za vnějšími hradbami, tj. v intervalu  $(x_{0,75} + 3q, \infty)$  či v intervalu  $(-\infty, x_{0,25} - 3q)$ .

**Příklad 6.:** Pro údaje z příkladu 1 sestrojte krabicový diagram.

**Řešení:**

Počet členů	1	2	3	4	5	6
Počet domácností	2	6	4	10	5	3

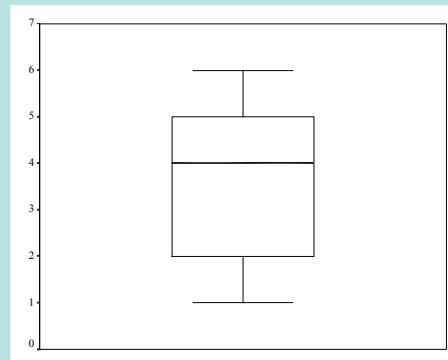
Rozsah souboru  $n = 30$ . Výpočty potřebných kvantilů uspořádáme do tabulky.

$\alpha$	$n\alpha$	c		$x_\alpha$
0,25	7,5	8	$x_{(c)} = x_{(8)}$	2
0,50	15	15	$\frac{x_{(15)} + x_{(16)}}{2}$	4
0,75	22,5	23	$x_{(c)} = x_{(23)}$	5

$$q = 5 - 2 = 3$$

$$\text{Dolní vnitřní hradba: } x_{0,25} - 1,5q = 2 - 1,5 \cdot 3 = -2,5$$

$$\text{Horní vnitřní hradba: } x_{0,75} + 1,5q = 5 + 1,5 \cdot 3 = 9,5$$

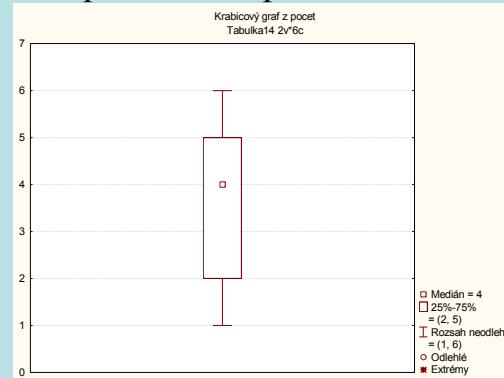


Vidíme, že datový soubor vykazuje určitou nesymetrii – medián je posunut směrem k hornímu kvartilu, soubor je tedy záporně sešikmen. V souboru se nevyskytují žádné odlehlé ani extrémní hodnoty.

## Výpočet pomocí systému STATISTICA:

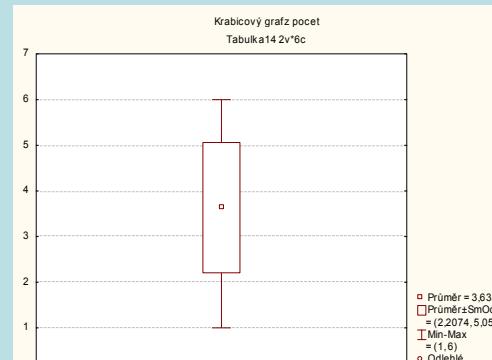
Otevřeme nový datový soubor o 2 proměnných a 6 případech. První proměnnou nazveme počet, druhou ctnost a zapíšeme do nich počet členů domácnosti a odpovídající absolutní četnosti. Zvolíme Grafy – 2D Grafy – Krabicové grafy.

Zapneme proměnnou vah ctnost, zadáme závisle proměnnou pocet a dostaneme krabicový diagram:



**Upozornění:** Máme-li data intervalového či poměrového charakteru, o nichž lze předpokládat, že pocházejí z nějakého symetrického rozložení (například normálního), je možné použít jinou variantu krabicového diagramu: bod či čára uvnitř krabice reprezentuje průměr, vodorovné hrany krabice jsou ve výšce průměr  $\pm$  směrodatná odchylka a svorky končí v minimu či maximu.

V našem případě dostaneme krabicový diagram:



Před uvedením dalších diagnostických grafů je nutné zavést pojem pořadí čísla v posloupnosti čísel.

### Pojem pořadí

Nechť  $x_1, \dots, x_n$  je posloupnost reálných čísel.

- a) Jsou-li čísla navzájem různá, pak pořadím  $R_i$  čísla  $x_i$  rozumíme počet těch čísel  $x_1, \dots, x_n$ , která jsou menší nebo rovna číslu  $x_i$ .
- b) Vyskytují-li se mezi danými čísly skupinky stejných čísel, pak každé takové skupince přiřadíme průměrné pořadí.

### Příklad na stanovení pořadí

- a) Jsou dána čísla 9, 4, 5, 7, 3, 1. Stanovte pořadí těchto čísel.
- b) Jsou dána čísla 6, 7, 7, 9, 6, 10, 8, 6, 6, 9.

### Řešení

ad a)

usp. čísla	1	3	4	5	7	9
pořadí	1	2	3	4	5	6

ad b)

usp. čísla	6	6	6	6	7	7	8	9	9	10
pořadí	1	2	3	4	5	6	7	8	9	10
prům. pořadí	2,5	2,5	2,5	2,5	5,5	5,5	7	8,5	8,5	10

## Normální pravděpodobnostní graf (N-P plot)

N-P plot umožňuje graficky posoudit, zda data pocházejí z normálního rozložení.

### Způsob konstrukce:

Na vodorovnou osu vynášíme uspořádané hodnoty  $x_{(1)} \leq \dots \leq x_{(n)}$ ,

na svislou osu kvantily  $u_{\alpha_j}$  standardizovaného normálního rozložení, kde  $\alpha_j = \frac{3j - 3}{3n + 1}$ , přičemž  $j$  je pořadí  $j$ -té uspořádané hodnoty (jsou-li některé hodnoty stejné, pak za  $j$  bereme průměrné pořadí odpovídající takové skupince).

Pocházejí-li data z normálního rozložení, pak všechny dvojice  $(x_{(j)}, u_{\alpha_j})$  budou ležet na přímce.

Pro data z rozložení s kladnou šikmostí se dvojice  $(x_{(j)}, u_{\alpha_j})$  budou řadit do **konkávní křivky**,

pro data z rozložení se zápornou šikmostí se dvojice  $(x_{(j)}, u_{\alpha_j})$  budou řadit do **konvexní křivky**.

## Příklad na konstrukci N – P plotu:

Desetkrát nezávisle na sobě byla změřena jistá konstanta. Výsledky měření: 2 1,8 2,1 2,4 1,9 2,1 2 1,8 2,3 2,2. Pomocí normálního pravděpodobnostního grafu posudíte, zda se tato data řídí normálním rozložením.

## Řešení:

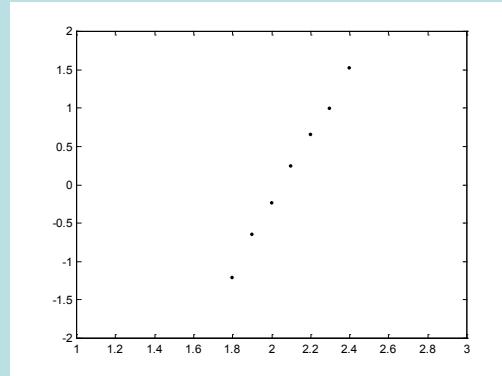
usp. hodnoty	1,8	1,8	1,9	2	2	2,1	2,1	2,2	2,3	2,4
pořadí	1	2	3	4	5	6	7	8	9	10
průměrné pořadí	1,5	1,5	3	4,5	4,5	6,5	6,5	8	9	10

Vektor hodnot průměrného pořadí:  $j = (1,5 \ 3 \ 4,5 \ 6,5 \ 8 \ 9 \ 10)$ ,

$$\text{vektor hodnot } \alpha_j = \frac{3j - 1}{3n + 1} = [0,1129; 0,2581; 0,4032; 0,5968; 0,7419; 0,8387; 0,9355]$$

$$\text{vektor kvantilů } u_{\alpha_j} = [-0,2112; -0,6493; -0,245; 0,245; 0,6493; 0,9892; 1,5179]$$

Normální pravděpodobnostní graf

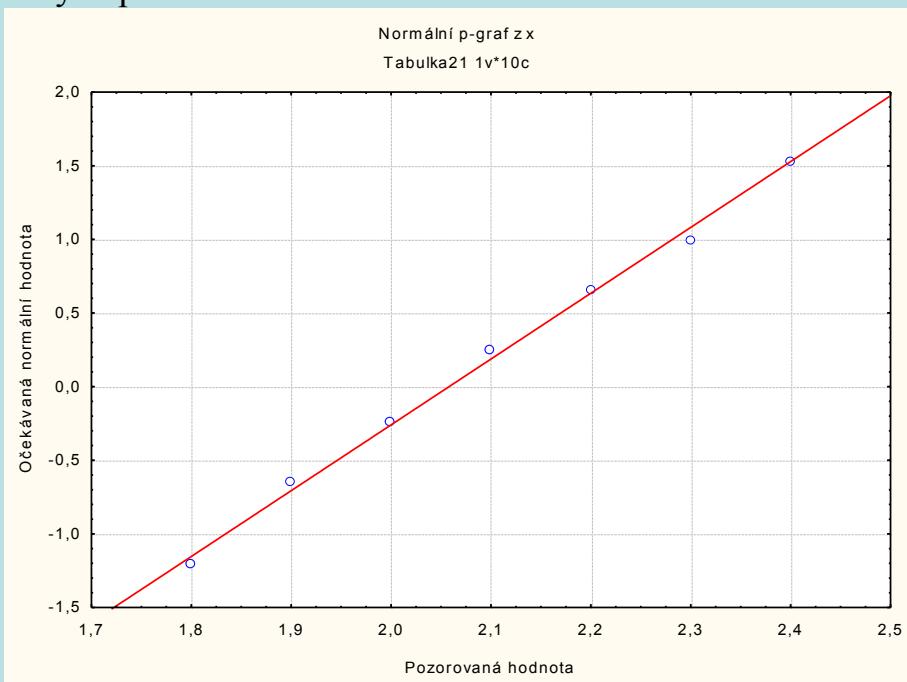


Protože dvojice  $(x_{(j)}, u_{\alpha_j})$  téměř leží na přímce, lze usoudit, že data pocházejí z normálního rozložení.

## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o jedné proměnné a 10 případech. Zjištěné hodnoty zapíšeme do proměnné X.

Grafy – 2D Grafy – Normální pravděpodobnostní grafy – Proměnná X – OK - odškrtneme Neurčovat průměrnou pozici svázaných pozorování - OK.



## Quantile - quantile plot (Q-Q plot)

Umožňuje graficky posoudit, zda data pocházejí z nějakého známého rozložení (např. STATISTICA nabízí 8 typů rozložení: beta, exponenciální, Gumbelovo, gamma, log-normální, normální, Rayleighovo a Weibulovo).

### Způsob konstrukce:

na svislou osu vynášíme uspořádané hodnoty  $x_{(1)} \leq \dots \leq x_{(n)}$ ,

na vodorovnou osu kvantily  $K_{\alpha_j}(x)$  vybraného rozložení, kde  $\alpha_j = \frac{j - r_{adj}}{n + 1_{adj}}$ , přičemž  $r_{adj}$  a  $n_{adj}$  jsou korigující faktory  $\leq 0,5$ ,

implicitně  $r_{adj} = 0,375$  a  $n_{adj} = 0,25$ . (Jsou-li některé hodnoty  $x_{(1)} \leq \dots \leq x_{(n)}$  stejné, pak za  $j$  bereme průměrné pořadí odpovídající takové skupince.)

Pokud vybrané rozložení závisí na nějakých parametrech, pak se tyto parametry odhadnou z dat nebo je může zadat uživatel.

Body  $(K_{\alpha_j}(x), x_{(j)})$  se metodou nejmenších čtverců proloží přímka. Čím méně se body odchylují od této přímky, tím je lepší soulad mezi empirickým a teoretickým rozložením.

**Příklad na konstrukci Q-Q plotu:** Desetkrát nezávisle na sobě byla změřena jistá konstanta. Výsledky měření: 2 1,8 2,1 2,4 1,9 2,1 2 1,8 2,3 2,2. Pomocí Q-Q plotu ověřte, zda se tato data řídí normálním rozložením.

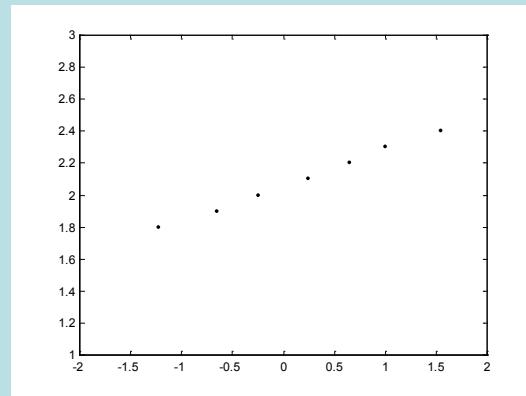
### Řešení:

usp.hodnoty	1,8	1,8	1,9	2	2	2,1	2,1	2,2	2,3	2,4
pořadí	1	2	3	4	5	6	7	8	9	10
průměrné pořadí	1,5	1,5	3	4,5	4,5	6,5	6,5	8	9	10

Vektor hodnot průměrného pořadí:  $j = (1,5 \ 3 \ 4,5 \ 6,5 \ 8 \ 9 \ 10)$

$$\text{vektor hodnot } \alpha_j = \frac{j - 0,375}{n + 0,25} = [0,1098; 0,2561; 0,4024; 0,5976; 0,7439; 0,8415; 0,939]$$

$$\text{vektor kvantilů } u_{\alpha_j} = [-0,2278; -0,6554; -0,247; 0,247; 0,6554; 1,0005; 1,566]$$

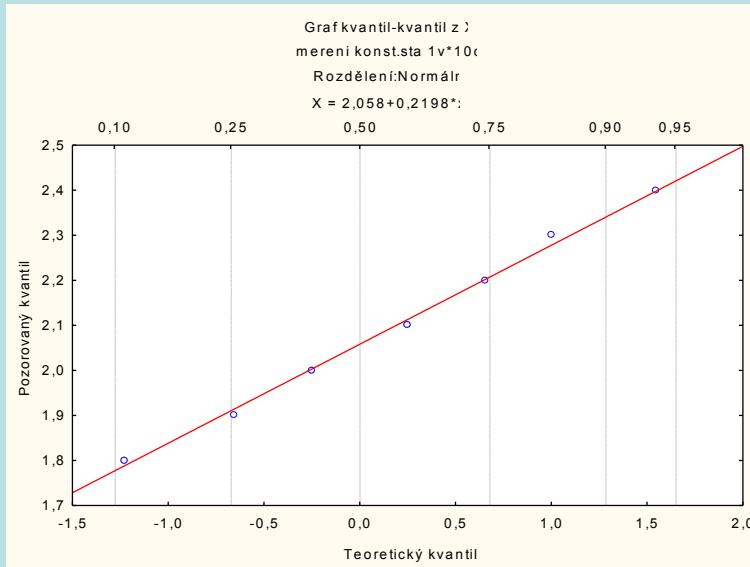


Vzhled grafu nasvědčuje tomu, že data pocházejí z normálního rozložení.

## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o jedné proměnné a 10 případech. Zjištěné hodnoty zapíšeme do proměnné X.

Grafy – 2D Grafy – Grafy typu Q-Q – Proměnná X – OK - odškrtneme Neurčovat průměrnou pozici svázaných pozorování - OK.



## Probability - probability plot (P-P plot)

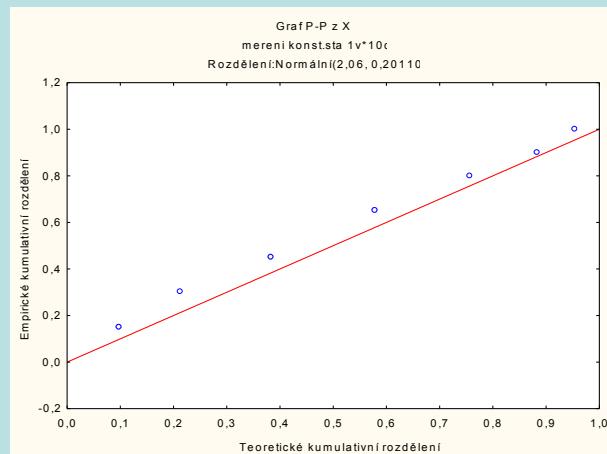
Používá se ke stejným účelům jako Q-Q plot, ale jinak se konstruuje.

**Způsob konstrukce:** spočtou se standardizované hodnoty  $z_j = \frac{x_j - \bar{x}}{s}$ ,  $j = 1, \dots, n$ . Na vodorovnou osu se vynesou hodnoty teoretické distribuční funkce  $\Phi(z_{(j)})$  a na svislou osu hodnoty empirické distribuční funkce  $F(z_{(j)}) = j/n$ . (Jsou-li některé hodnoty  $x_{(1)} \leq \dots \leq x_{(n)}$  stejné, pak za  $j$  bereme průměrné pořadí odpovídající takové skupince.) Pokud se body  $(\Phi(z_{(j)}), F(z_{(j)}))$  řadí kolem hlavní diagonály čtverce  $[0,1] \times [0,1]$ , lze usuzovat na dobrou shodu empirického a teoretického rozložení.

**Příklad na konstrukci P-P plotu pomocí systému STATISTICA:** Desetkrát nezávisle na sobě byla změřena jistá konstanta. Výsledky měření: 2 1,8 2,1 2,4 1,9 2,1 2 1,8 2,3 2,2. Pomocí P-P plotu ověřte, zda se tato data řídí normálním rozložením.

## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o jedné proměnné a 10 případech. Zjištěné hodnoty zapíšeme do proměnné X. Grafy – 2D Grafy – Grafy typu P-P – Proměnná X – OK - odškrtneme Neurčovat průměrnou pozici svázaných pozorování - OK.



## Histogram

Umožňuje porovnat tvar hustoty četnosti s tvarem hustoty pravděpodobnosti vybraného teoretického rozložení. (Ve STATISTICE je pojem histogramu širší, skrývá se za ním i sloupkový diagram.)

**Způsob konstrukce:** na vodorovnou osu vynášíme meze třídicích intervalů. Nad každým třídicím intervalem sestrojíme obdélník o ploše odpovídající relativní četnosti příslušného třídicího intervalu, tj. výška obdélníku je rovna četnostní hustotě třídicího intervalu (četnostní hustota je relativní četnost třídicího intervalu dělená délkou tohoto intervalu).

**Způsob konstrukce ve STATISTICE:** na vodorovnou osu se vynášejí třídicí intervaly (implicitně 10, jejich počet lze změnit, stejně tak i meze třídicích intervalů) či varianty znaku a na svislou osu absolutní nebo relativní četnosti třídicích intervalů či variant. Do histogramu se zakreslí tvar hustoty (či pravděpodobnostní funkce) vybraného teoretického rozložení.

## Příklad na konstrukci histogramu:

U 70 domácností byly zjištovány týdenní výdaje na nealkoholické nápoje (v Kč).

Výdaje	$\langle 5, 65 \rangle$	$\langle 65, 95 \rangle$	$\langle 95, 125 \rangle$	$\langle 125, 155 \rangle$	$\langle 155, 185 \rangle$	$\langle 185, 215 \rangle$
Počet dom.	7	16	27	14	4	2

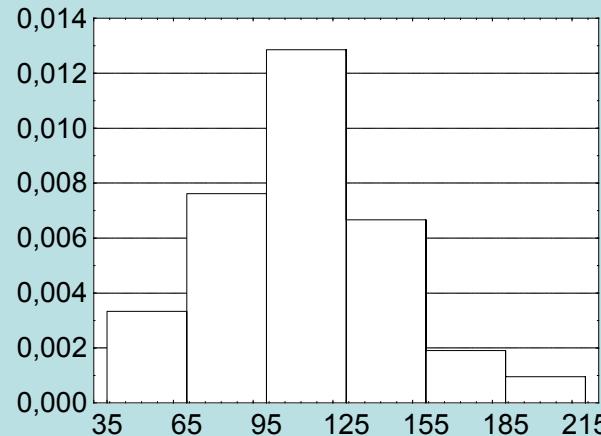
Nakreslete histogram.

## Řešení:

Nejprve sestavíme tabulku rozložení četností:

$[u_j, u_{j+}]$	$x_{[j]}$	$d_j$	$n_j$	$p_j$	$N_j$	$F_j$	$f_j$
$\langle 5, 65 \rangle$	50	30	7	$7/70=0,1$	7	$7/70=0,1$	$7/2100=0,0033$
$\langle 65, 95 \rangle$	80	30	16	$16/70=0,23$	23	$23/70=0,33$	$16/2100=0,0076$
$\langle 95, 125 \rangle$	110	30	27	$27/70=0,38$	50	$50/70=0,71$	$23/2100=0,0109$
$\langle 125, 155 \rangle$	140	30	14	$14/70=0,2$	64	$64/70=0,91$	$14/2100=0,0067$
$\langle 155, 185 \rangle$	170	30	4	$4/70=0,06$	68	$68/70=0,97$	$4/2100=0,0019$
$\langle 185, 215 \rangle$	200	30	2	$2/70=0,03$	70	$70/70=1$	$2/2100=0,00010$

S pomocí této tabulky sestrojíme histogram:

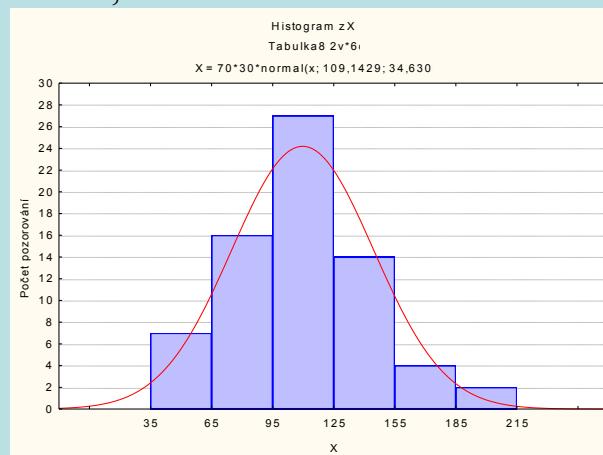


## Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o dvou proměnných a 6 případech. První proměnnou nazveme X, druhou cetnost. Do proměnné X napíšeme středy třídicích intervalů, do proměnné cetnost odpovídající absolutní četnosti:

	X	cetnost
1	50	7
2	80	16
3	110	27
4	140	14
5	170	4
6	200	2

Grafy – Histogramy – zadáme proměnnou vah cetnost – Proměnná X - zaškrtneme Hranice – Určit hranice – zaškrtneme Zadejte hraniční rozmezí: Minimum 35, Krok 30, Maximum 215 – OK – OK. Dostaneme graf:



Na rozdíl od histogramu konstruovaného ručně jsou na svislé ose absolutní četnosti, nikoliv četnostní hustoty. V porovnání s grafem hustoty normálního rozložení je vidět, že naše rozložení četností je lehce kladně zešikmené. Naše data tedy nepocházejí z normálního rozložení.

## Vzhled diagnostických grafů pro rozložení s různou šikmostí

Pro ilustraci se podívejme, jak se různá šikmost rozložení projeví na histogramu, N-P plotu a na krabicovém diagramu.

