2. kapitola

Exploratorní analýza dat

Řešení praktických úloh z Kompendia, str. 81.

Postup analýzy dat

1. Průzkumová analýza dat:

Diagnostické grafy: *stupeň symetrie rozdělení*
lokální koncentrace dat
vybočující data

2. Ověření předpokladů výběru dat:

Diagnosticky, testy: *ověření normality*
ověření nezávislosti
ověření homogenity
určení minimální četnosti

3. Transformace dat:

Analýza dat: *originální data*
data po mocninné transformaci
data po Box-Coxově transformaci

4. Parametry polohy, rozptýlení a tvaru:

Analýza 1 výběru: *klasické odhady* - *průměr*
- *rozptyl*

robustní odhady - *medián*
- *uřezané průměry*
- *winsorizovaný rozptyl*
- *interkvantilové rozpětí*

adaptivní odhady

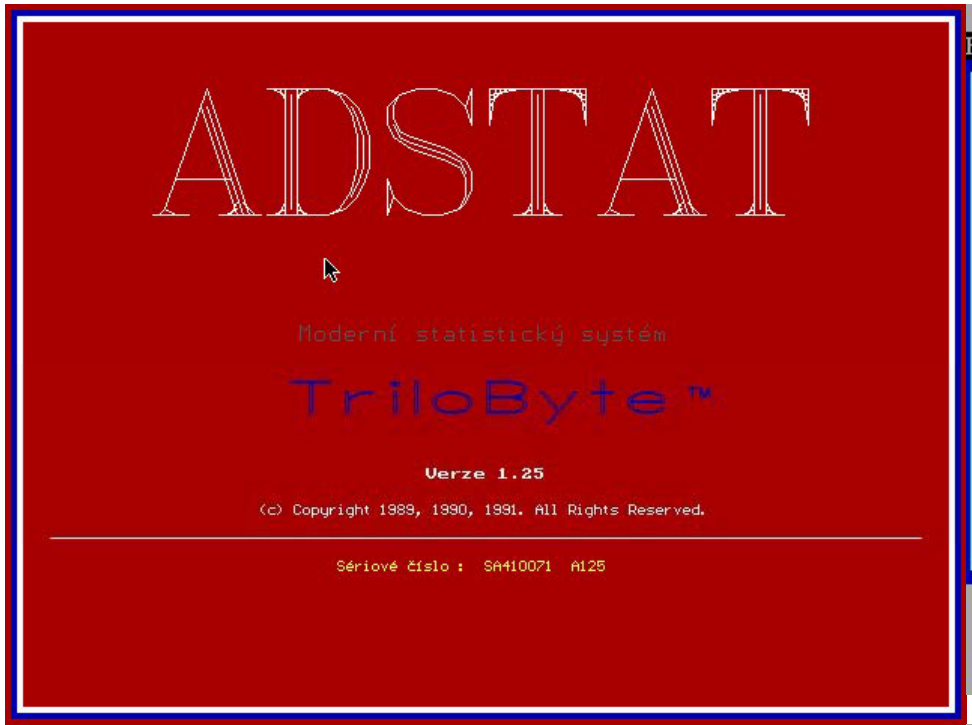

Načtení dat po F3.

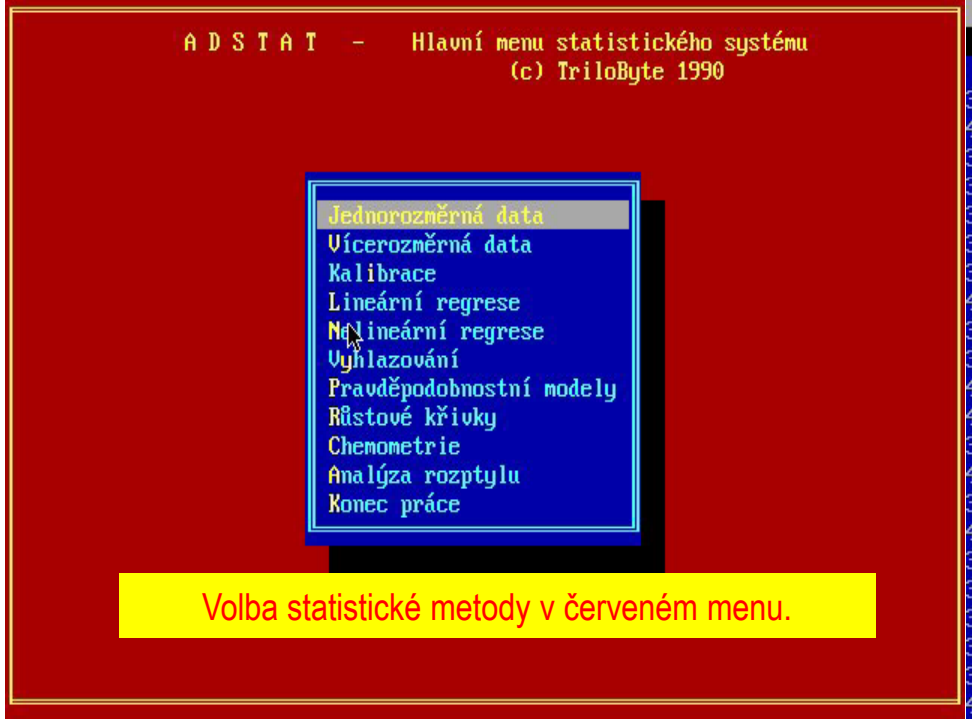

Volba statistické metody v červeném menu.

Načtená data úlohy B201 je možné v editoru ještě opravovat.

1. Průzkumová analýza dat:

Diagnostické grafy: *stupeň symetrie rozdělení*
lokální koncentrace dat
vybočující data

Volba exploratorní analýzy.

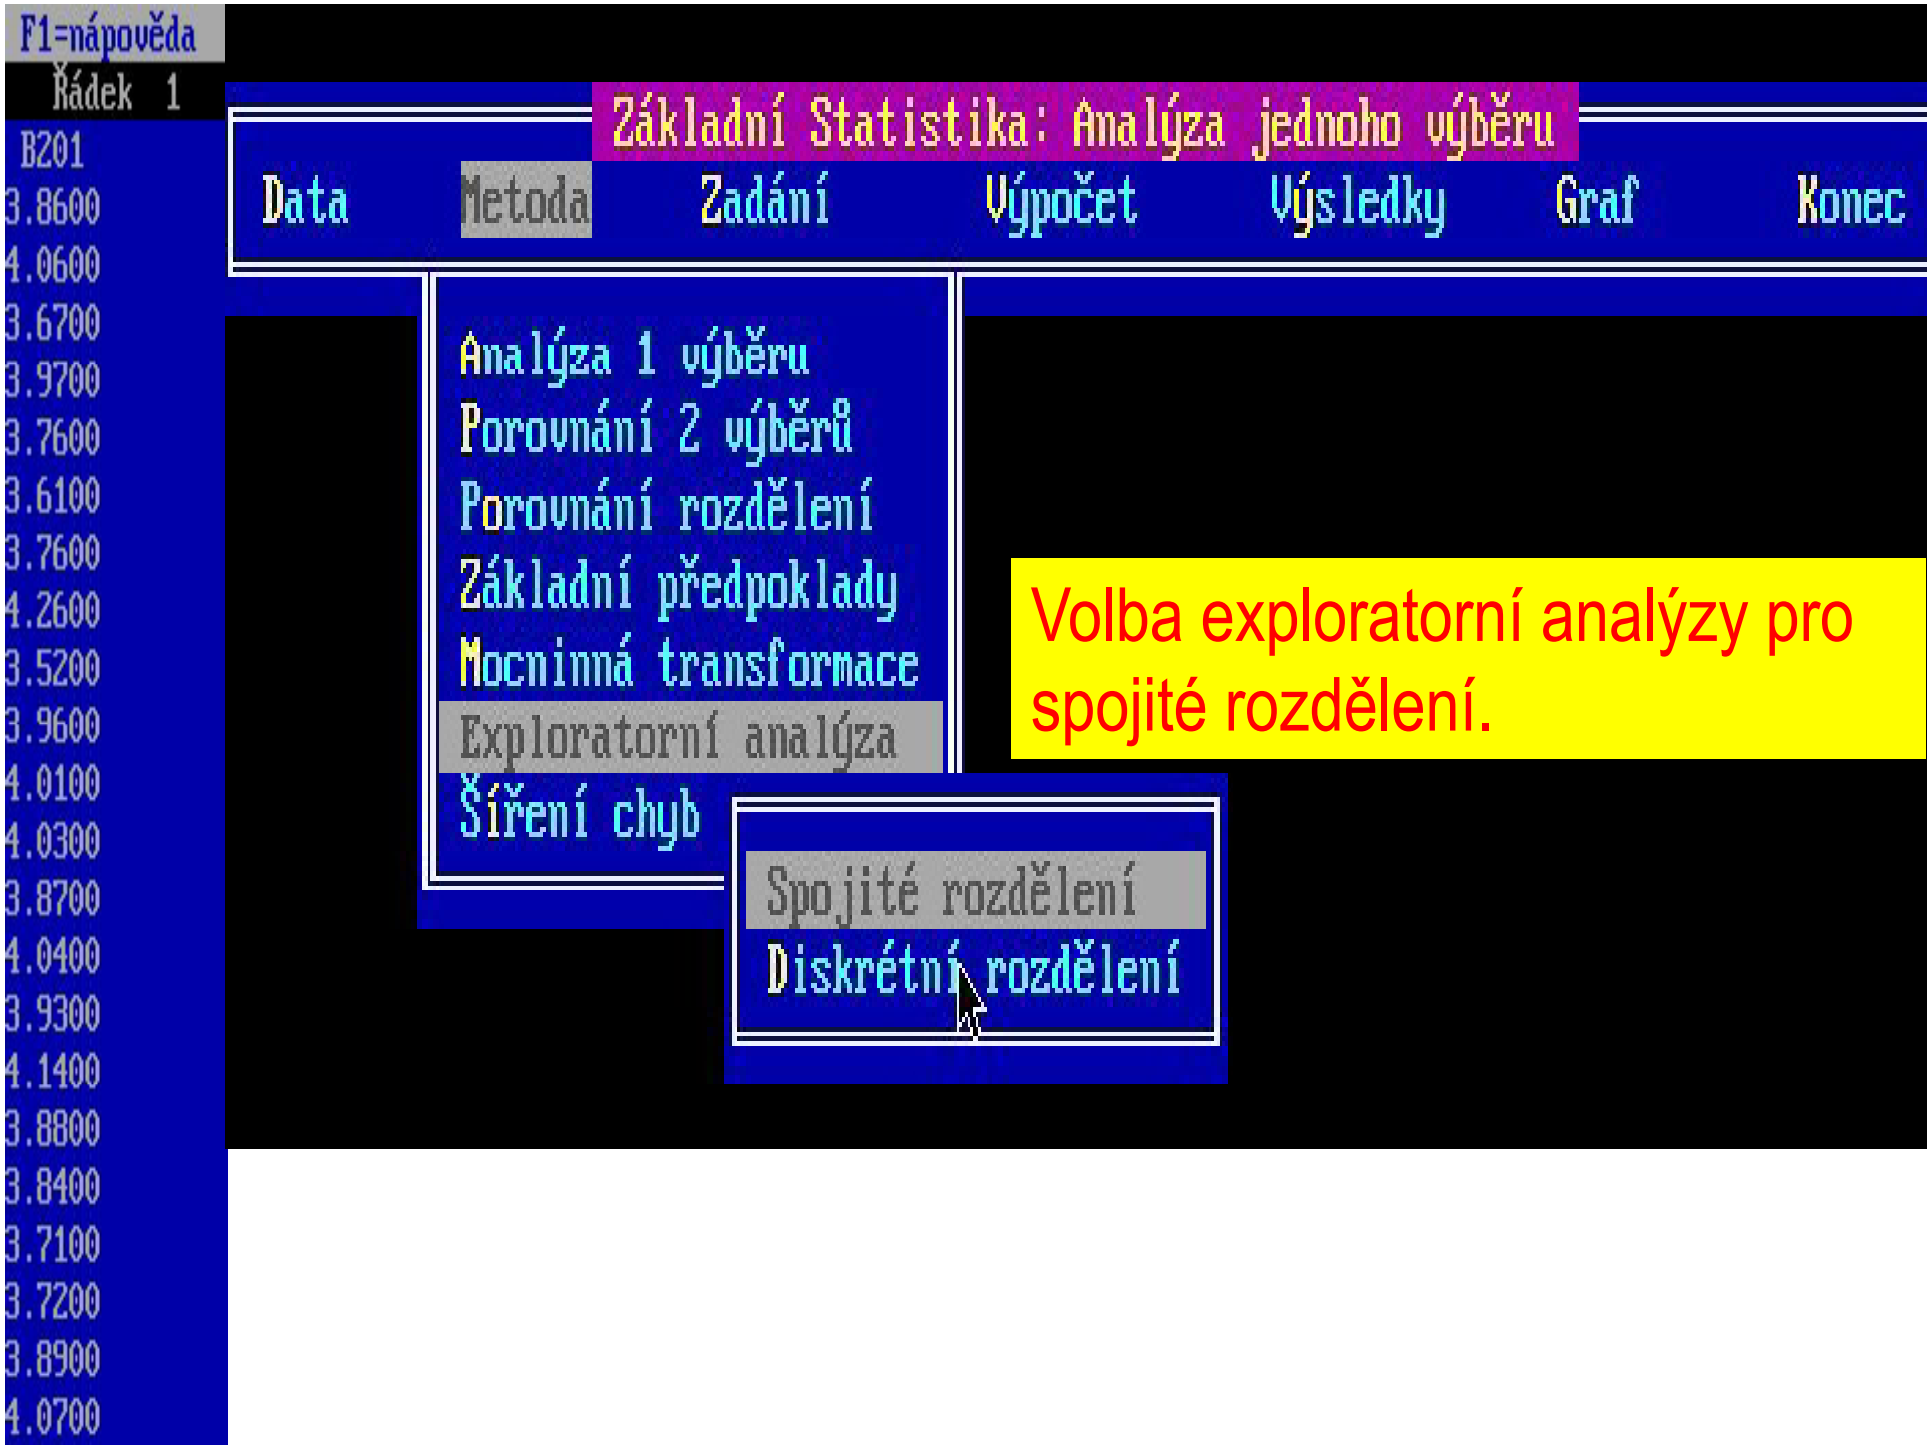

Volba exploratorní analýzy pro spojité rozdělení.

Základní Statistika: Exploratorní analýza spojitá

Data Metoda Zadání Výpočet Výsledky Graf Konec

Podmínky
Volby

Zadání podmínek výpočtu.

PODMÍNKY VÝPOČTU

Název: B201

Parametr alfa : _7.0000E-01

ČEKÁM ...

Základní Statistika: Exploratorní analýza spojitá

Data Metoda Zadání Výpočet Výsledky Graf Konec

Podmínky
Volby

Zadání podmínek výpočtu.

VOLBY

Kreslit histogram : Ano
Hladina významnosti: 0.050

Název výst. souboru: RESULTS .TXT

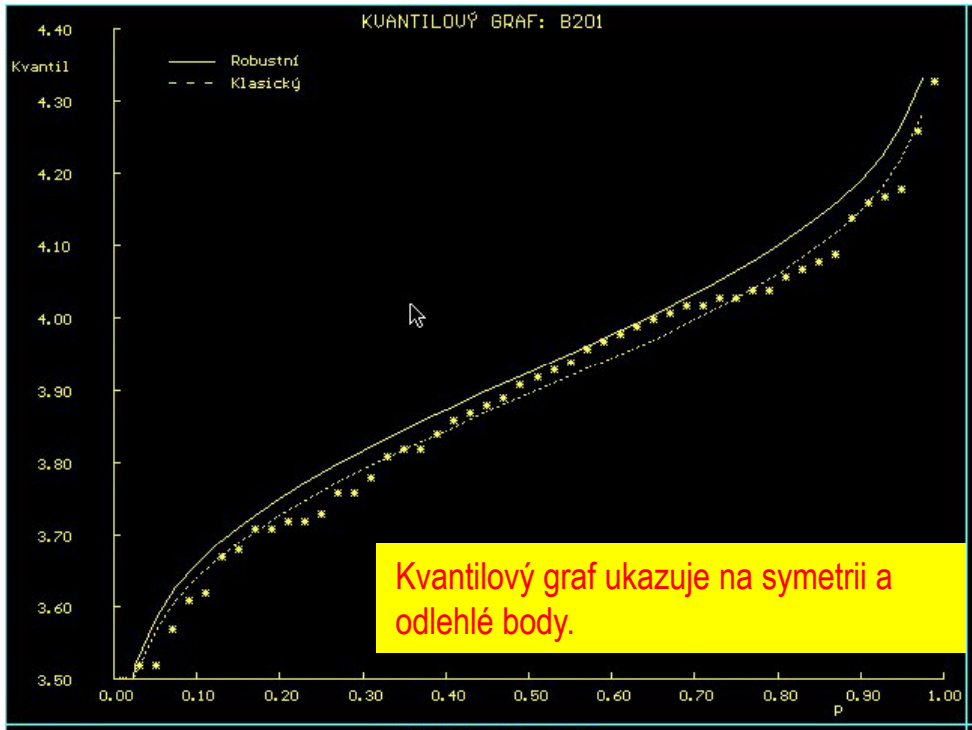

Kvantilový graf ukazuje na symetrii a odlehlé body.

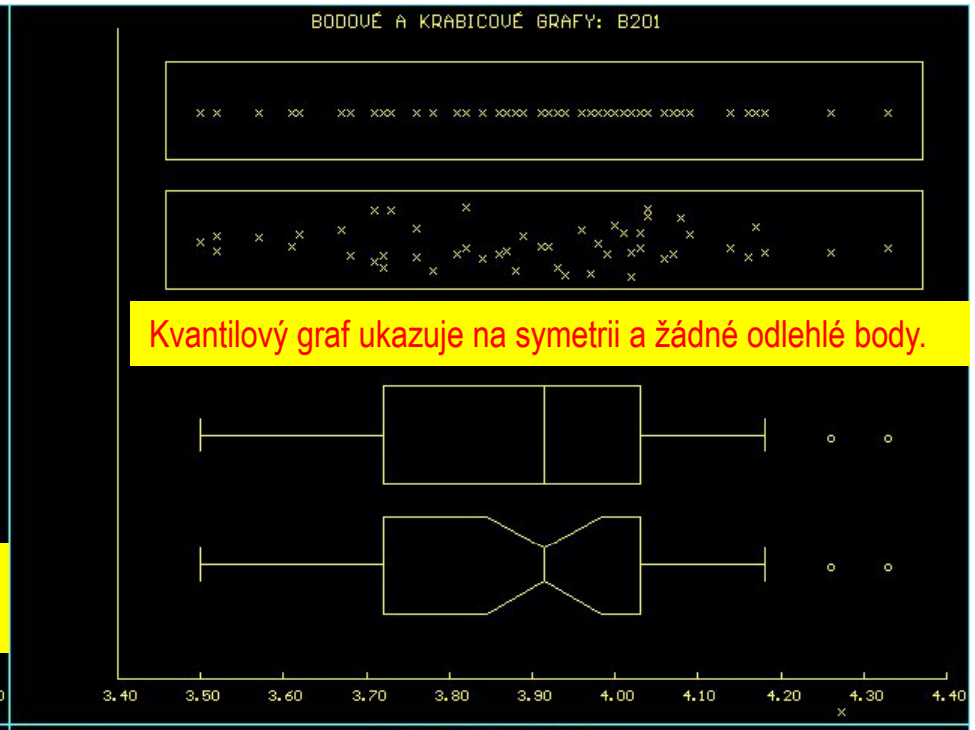

Kvantilový graf ukazuje na symetrii a žádné odlehlé body.

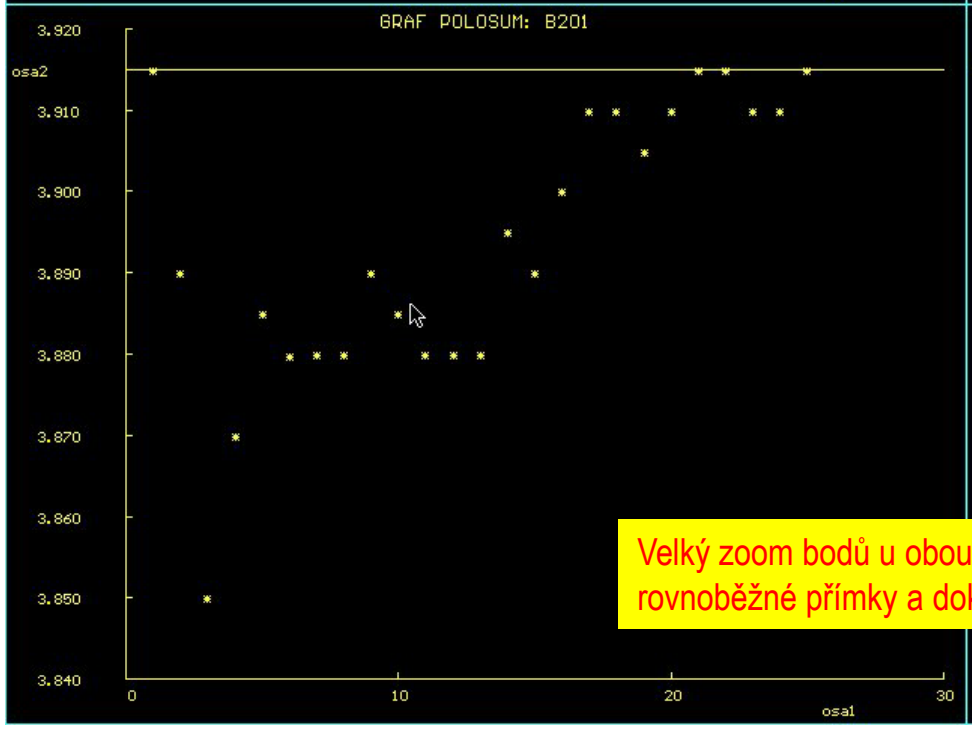

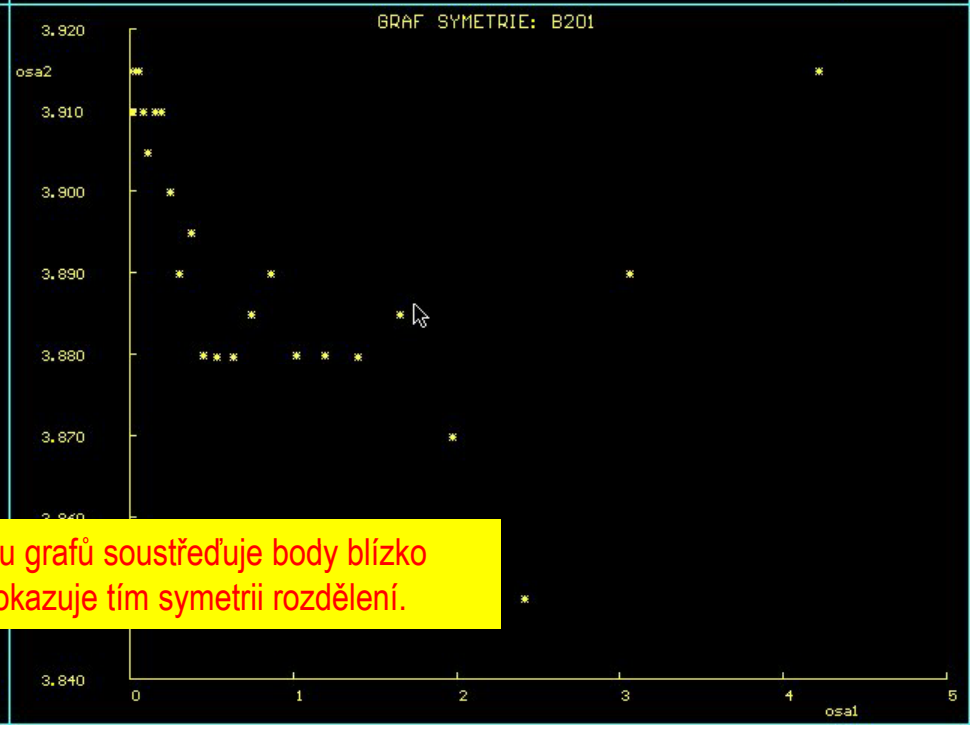

Velký zoom bodů u obou grafů soustřeďuje body blízko rovnoběžné přímky a dokazuje tím symetrii rozdělení.

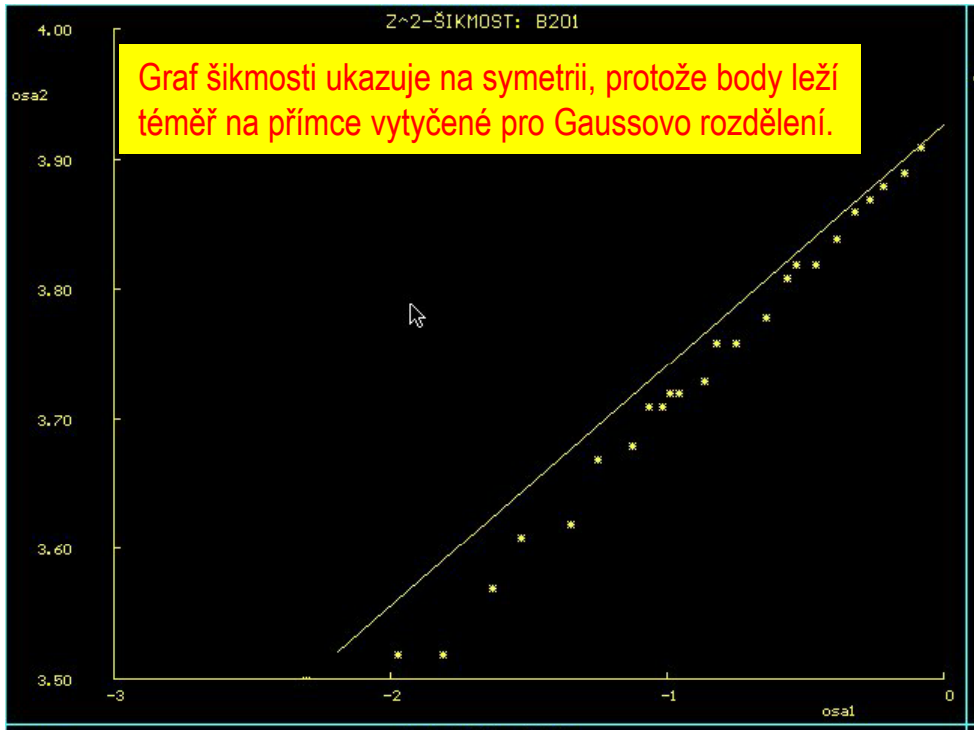

Graf šikmosti ukazuje na symetrii, protože body leží téměř na přímce vytyčené pro Gaussovo rozdělení.

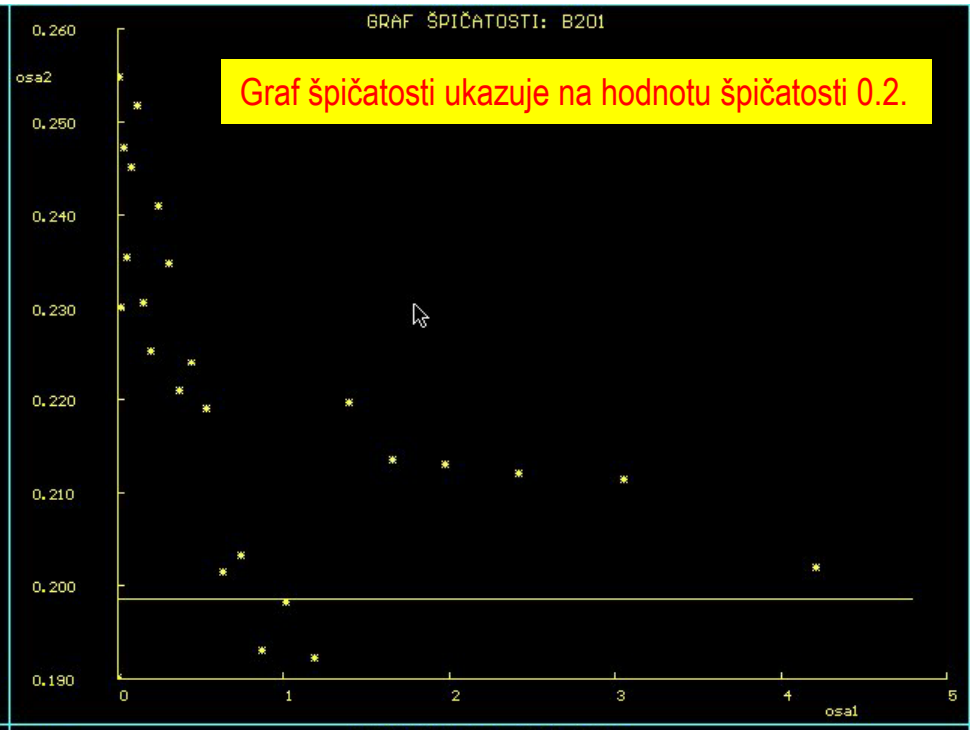

Graf špičatosti ukazuje na hodnotu špičatosti 0.2.

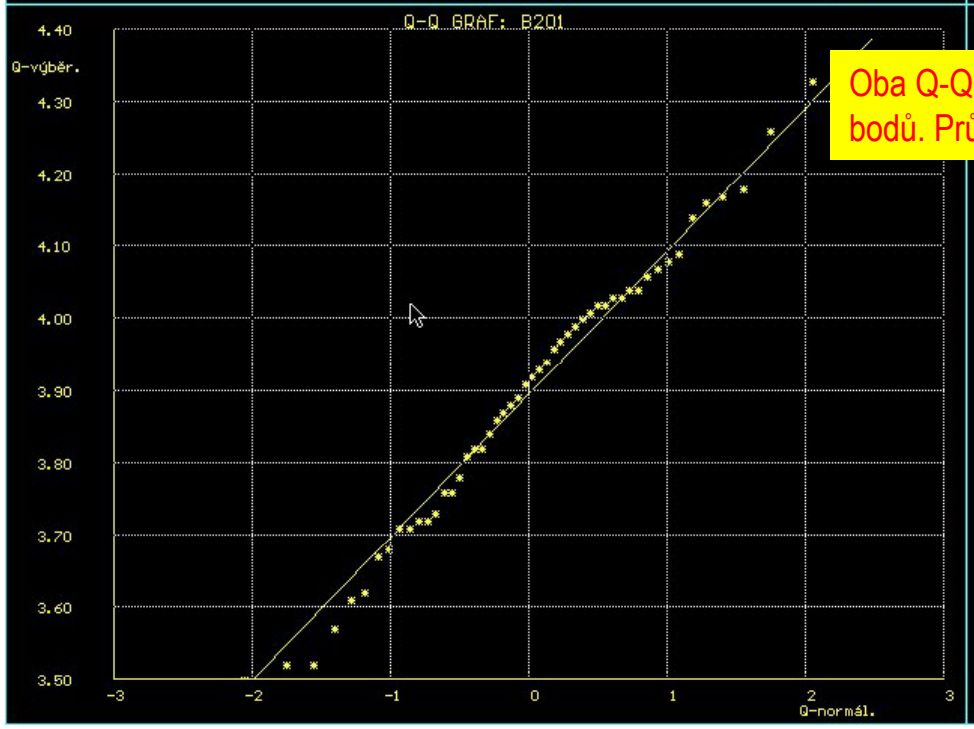

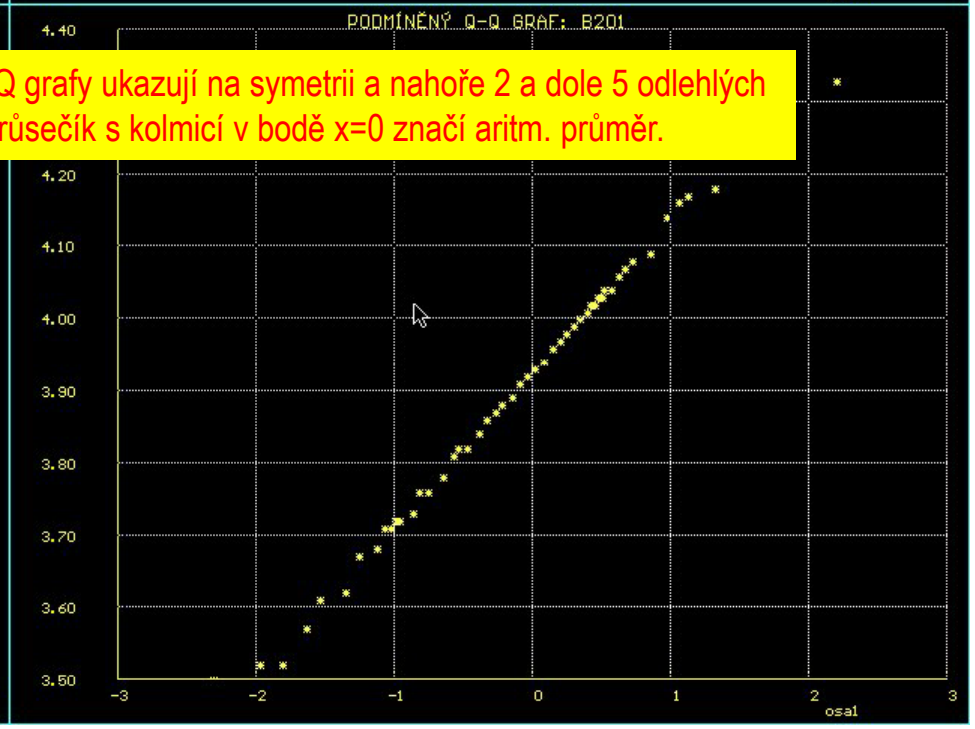

Oba Q-Q grafy ukazují na symetrii a nahoře 2 a dole 5 odlehlých bodů. Průsečík s kolmicí v bodě x=0 značí aritm. průměr.

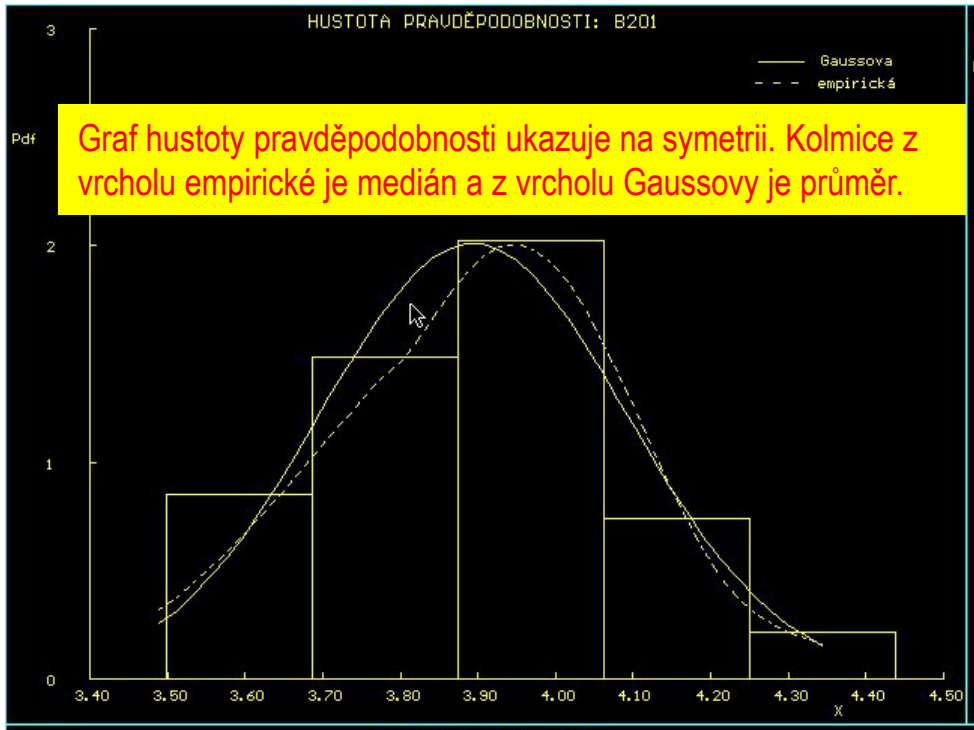

Graf hustoty pravděpodobnosti ukazuje na symetrii. Kolmice z vrcholu empirické je medián a z vrcholu Gaussovy je průměr.

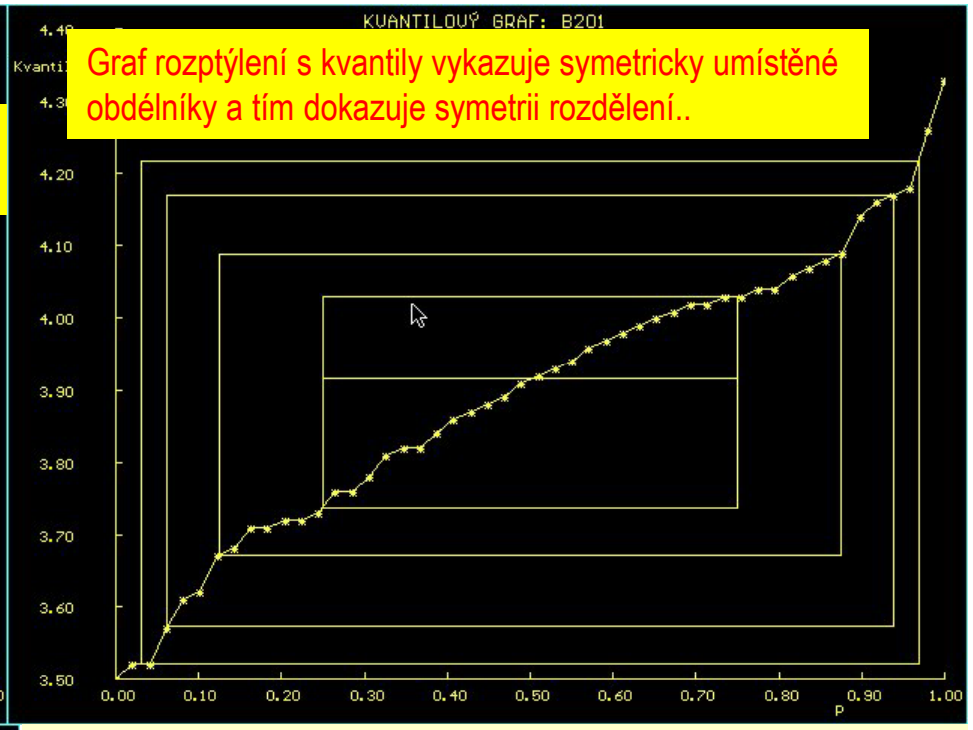

Graf rozptýlení s kvantily vykazuje symetricky umístěné obdélníky a tím dokazuje symetrii rozdělení..

Kruhovým grafem je elipsa s x-osou rovnoběžná, a proto je rozdělení symetrické, rovnoměrné až Gaussovo.

Závěr EDA:

1. Rozdělení je symetrické (mezi rovnoměrným a Gaussovým).

2. Rozdělení obsahuje nahoře 2 a dole cca 5 odlehlých bodů – outlierů.

3. Není asi nutné užít transformaci dat.

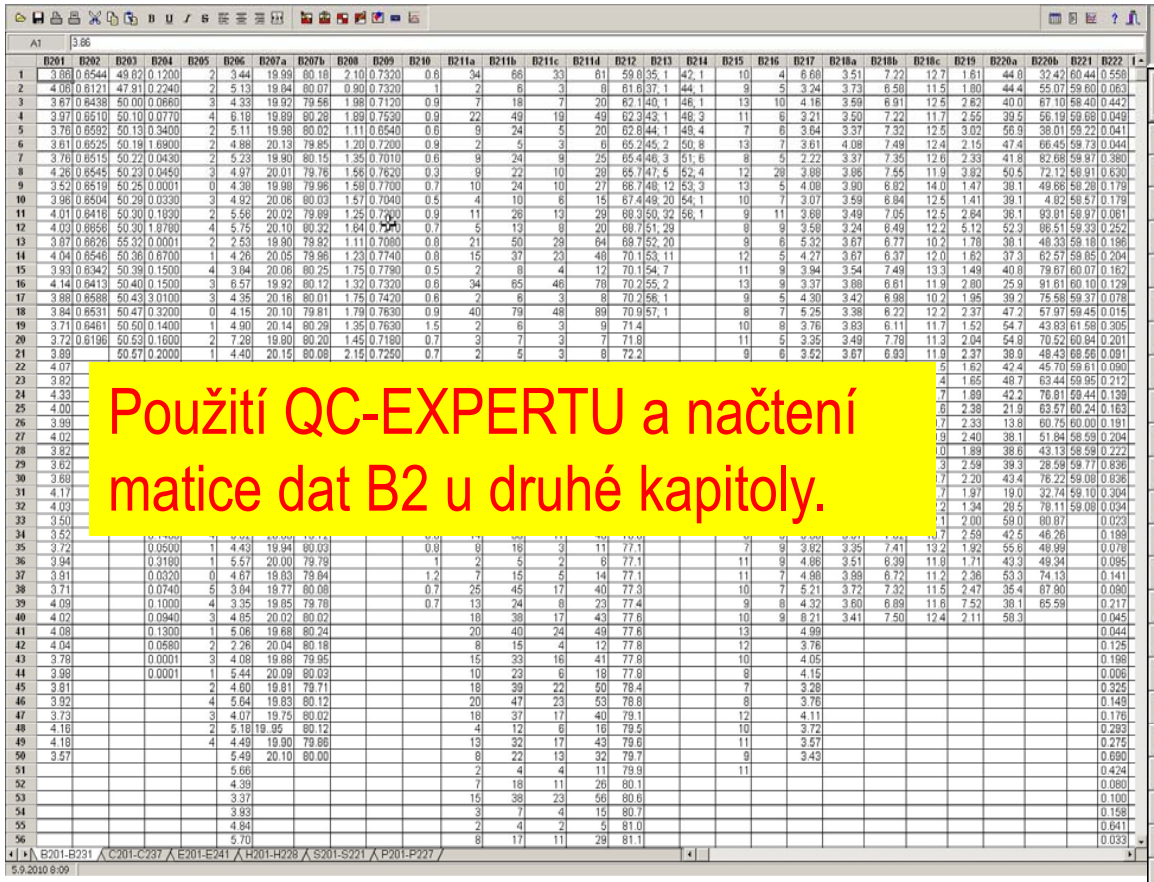

Použití QC-EXPERTU a načtení matice dat B2 u druhé kapitoly.

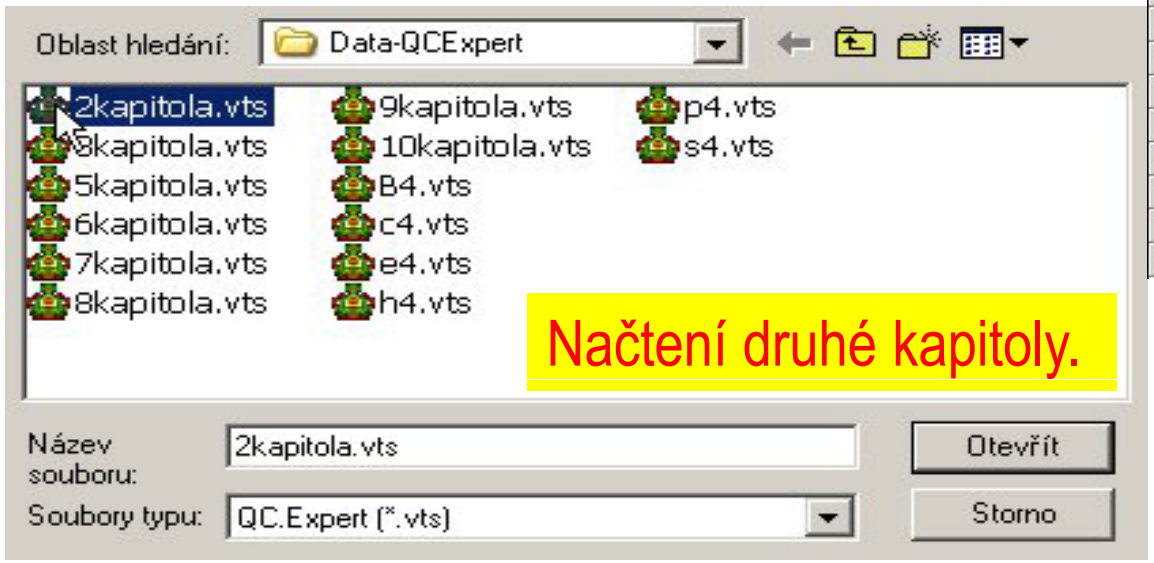

Načtení druhé kapitoly.

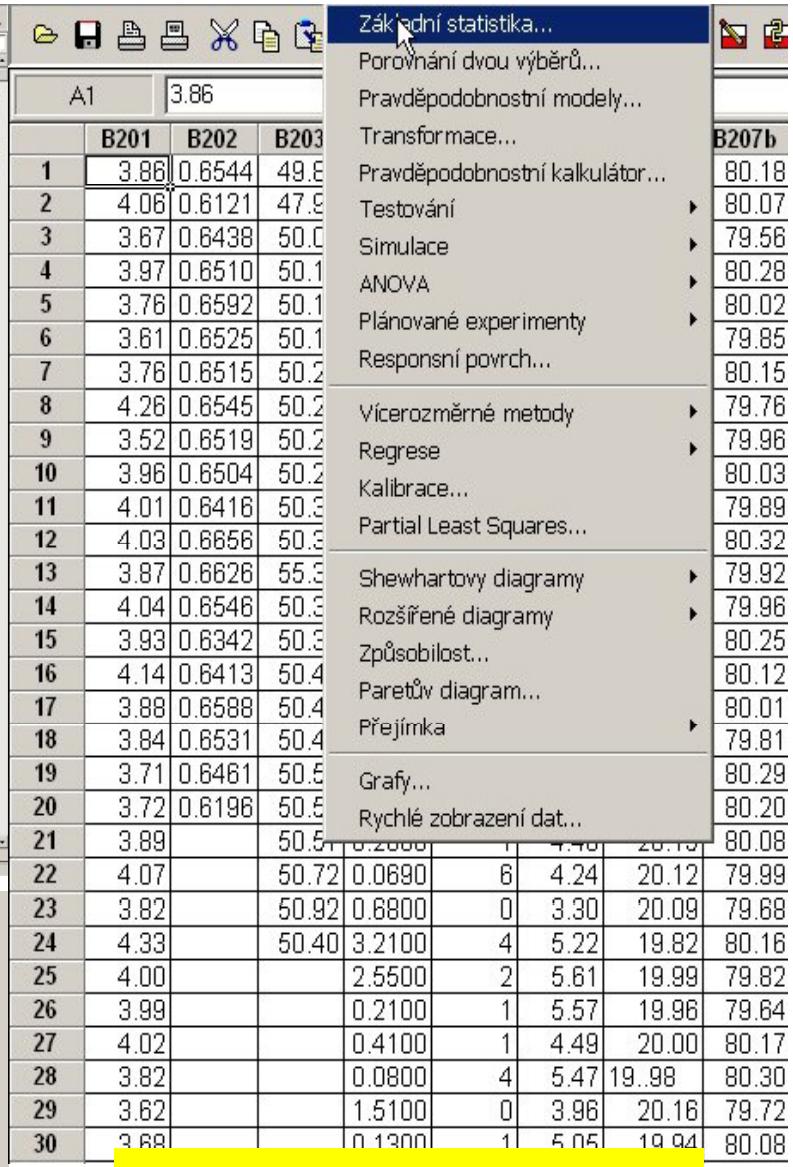

Volba výpočtů **Základní statistika.**

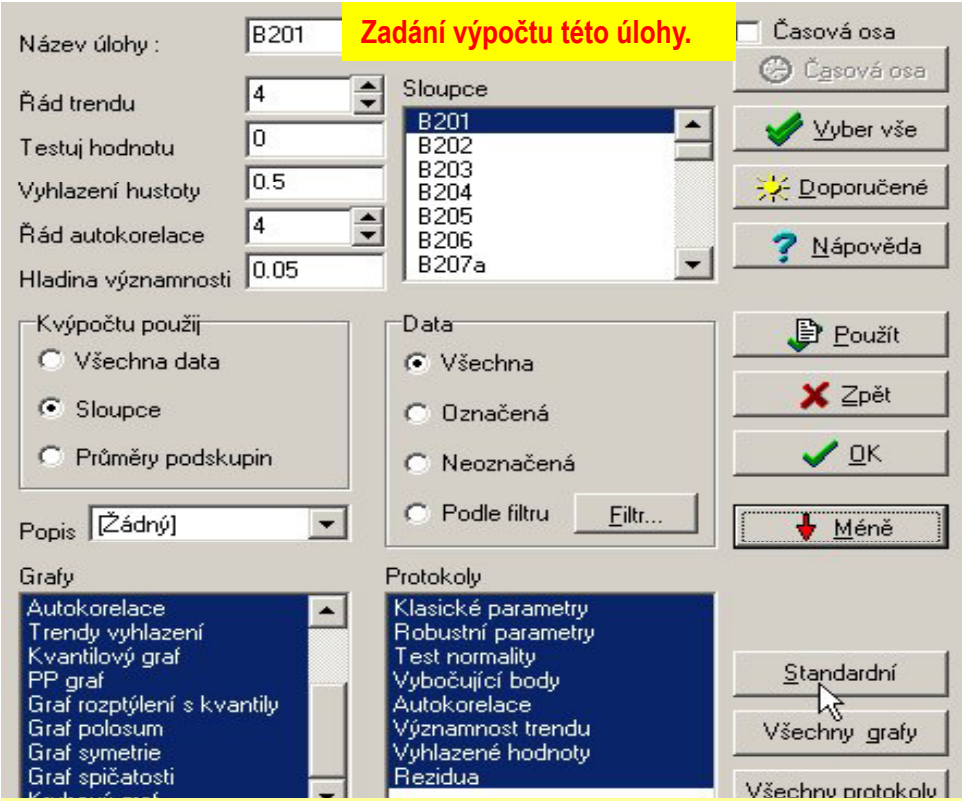

Data a parametry: Data jsou organizována do sloupců. V prvním řádku jsou názvy sloupce. Jsou-li ve vstupním dialogovém panelu vybrány "Všechna data" nebo "Sloupce", mohou být délky jednotlivých sloupců různé. Má-li se výpočet provést pro "Průměry podskupin, měly by všechny slupce mít stejnou délku. Minimální počet sloupců je 1. Minimální počet dat je 2.

Řád trendu určuje z kolika po sobě jdoucích dat budou počítány klouzavé průměry a klouzavé mediány Hodnota by měla být menší než polovina počtu dat.

Testuj hodnotu zadává se hodnota pro T-test. Program testuje na zadané hladině významnosti, zda tato hodnota může být shodná se střední hodnotou dat.

Vyhlazení hustoty udává šířku jádra pro jádrové vyhlazení pro graf hustoty pravděpodobnosti. Čím je větší, tím bude křivka hustoty pravděpodobnosti hladší a naopak. Hodnota musí být větší než nula.

Řád autokorelace udává do kterého řádu se budou počítat autokorelační koeficienty. Hodnota musí být alespoň o 2 menší než počet platných dat.

Hladina významnosti udává spolehlivost pro intervaly spolehlivosti a statistické testy. Musí být větší než nula a menší než 0.5. Vynásobena 100 udává hodnotu v procentech. Obvyklá hodnota je 0.05 (tedy 5%).

Všechna data všechny vybrané sloupce budou brány jako jediný sloupec.

Sloupce Výpočet se provede pro každý z vybraných sloupců zvlášť.

Průměry podskupin Výpočet se provede pro řádkové průměry z vybraných sloupců. Pokud nejsou sloupce stejně dlouhé, nebo obsahují chybějící data, provede se výpočet jen pro úplné řádky. Tento výpočet má význam především pro diagnostiku dat pro regulační diagramy typu x-průměr.

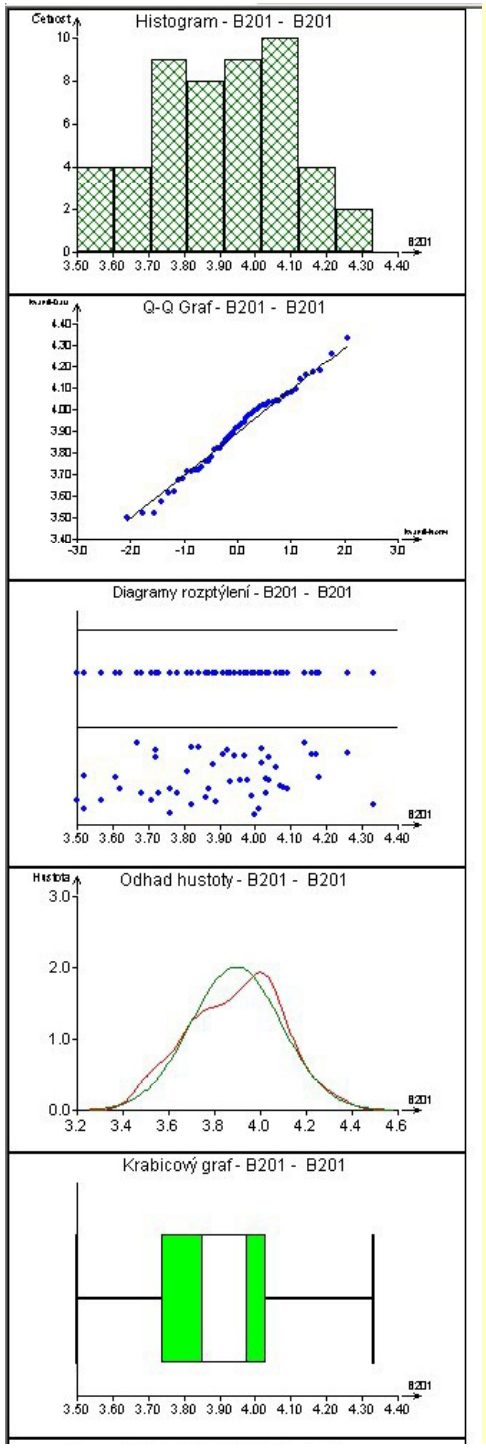

Grafy výstupu Exploratorní analýzy a jejich vysvětlení.

Histogram: nejstarší diagram rozdělení ukazuje na symetrii rozdělení. Histogram četností dat v jednotlivých třídách s konstantní šířkou; optimální počet tříd je stanovován automaticky s ohledem na počet dat.

Q-Q graf: kvantil-kvantilový graf vykazuje většinu bodů na přímce.
4 body dole a 2 body nahoře jsou podezřelé, že jsou odlehlé. Graf pro diagnostiku normality a odlehlých měření; pro normální data bez odlehlých měření má tvar přímky; pro normální data s odlehlými měřeními má tvar přímky s koncovými body ležícími mimo tuto přímku; pro systematicky sešikmená data s kladnou šikmostí (např. rozdělení lognormální, exponenciální) má nelineární konvexní tvar . Pro systematicky sešikmená data se zápornou šikmostí má nelineární konkávní tvar .

Diagramy rozptýlení: horní diagram rozptýlení a dolní rozmítnutý diagram rozptýlení ukazují na podezřelé body z odlehlosti. Zobrazuje všechna data ve skutečném měřítku na ose X. Popis osy Y nemá význam. Aby nedošlo ke splývání shodných nebo blízkých dat, jsou ve spodní polovině grafu zobrazena táž data, ale náhodně rozmítnutá (“rozházená“) na ose Y.

Jádrový odhad hustoty pravděpodobnosti: zelená křivka značí proložení teoretickým Gaussovým normálním rozdělením na bázi aritmetického průměru a směrodatné odchylky, zatímco červená křivka značí robustní proložení skutečným experimentálním rozdělením na bázi mediánu a kvartilového rozpětí. Porovnání průběhu hustoty pravděpodobnosti normálního rozdělení (plná čára) s jádrovým odhadem hustoty vypočítaným na základě dat (přerušovaná čára). Jádrový odhad používá Gaussovské jádro. Hladkost křivky jádrového odhadu je dána parametrem ”Vyhlazení hustoty” v dialogovém panelu, čím je parametr menší, tím podrobnější je průběh. V případě normality a většího množství dat jsou si obě křivky blízké.

Krabicový graf: ukazuje na symetrické rozdělení bez vybočujících bodů (outlierů). Větší obdélník ohraničuje vnitřních 50% dat, horní okraj zeleného (vyšrafovaného) obdélníku odpovídá 75% kvantilu, spodní okraj zeleného obdélníku odpovídá 25% kvantilu, střed bílého pruhu v zeleném obdélníku odpovídá mediánu, šířka pruhu odpovídá intervalu spolehlivosti mediánu, dva černé proužky jsou tzv. vnitřní hradby. Data mimo vnitřní hradby jsou označena červeným proužkem a lze je považovat za vybočující měření.

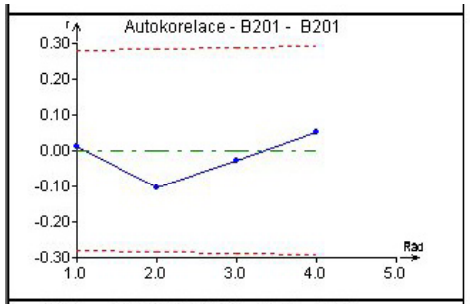

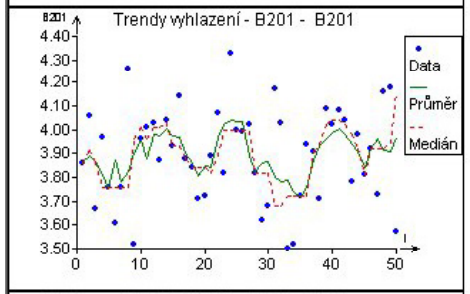

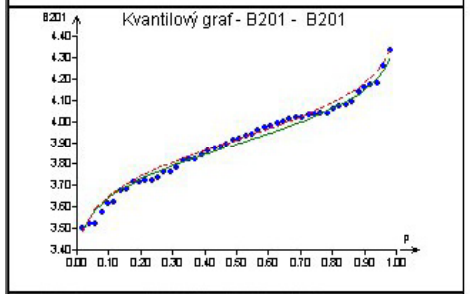

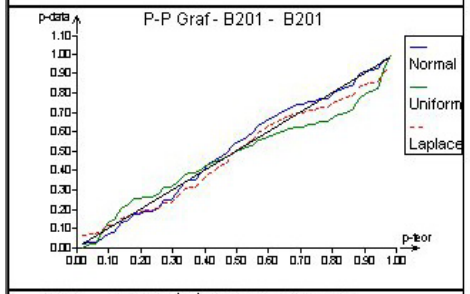

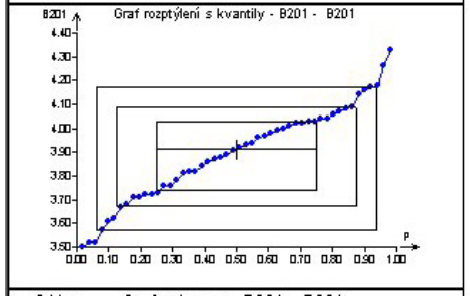

Graf autokorelace: data jsou nezávislá, protože leží mezi červenými intervaly.

Graf autokorelačních koeficientů až do řádu autokorelace zadaného v dialogovém panelu,. Červené meze ohraničují interval, v němž jsou koeficienty statisticky nevýznamné na zadané hladině významnosti. Překročí-li některý autokorelační koeficient tyto meze, je třeba považovat za závislá.

Graf trendů vyhlazení: v datech není trend.

Grafické znázornění trendu v datech pomocí klouzavého průměru (plná křivka) a klouzavého mediánu (přerušovaná křivka) na základě "Řádu trendu" zadaného v dialogovém panelu. Čím je řád trendu větší, tím jsou křivky hladší, méně citlivé na lokální poruchy a zachycují spíše globální dlouhodobý trend. Menší řád zachycuje spíše lokální chování dat. Klouzavý medián je méně citlivý (robustní) na lokální poruchy v datech a jednotlivá odlehlá měření a tedy vhodnější pro tyto případy.

Kvantilový graf: ukazuje na Gaussovo rozdělení.

Zobrazuje empirické kvantily dat proložené kvantilovou funkcí normálního rozdělení. Zelená křivka odpovídá funkci s klasickým průměrem a rozptylem (nerobustní), červená křivka odpovídá mediánu a mediánové odchylce (robustní). Podle toho, která z křivek lépe prokládá data, je vhodné zvolit jako odhad střední hodnoty průměr nebo medián.

P-P graf: podobnost exp. křivky s normální ukazuje na Gaussovo rozdělení.

Porovnává data s normálním (modrá křivka plná), Laplaceovým (zelená křivka) a rovnoměrným rozdělením pomocí teoretické a empirické distribuční funkce. Která křivka leží nejblíže černé přímce $y = x$, to rozdělení odpovídá experimentálním datům. Graf slouží pro rozlišení symetrických rozdělení podle špičatosti. Podobnost rovnoměrnému rozdělení ukazuje na možné vyloučení vysokých a nízkých hodnot, podobnost s Laplaceovým rozdělením ukazuje na možnou nekonstantnost rozptylu dat.

Graf rozptýlení s kvantily: symetrie obdélníků ukazuje na Gaussovo rozdělení.

Body grafu jsou vizuálně i významově shodné s kvantilovým grafem. Vzájemná poloha obdélníků odpovídá symetrii, resp. asymetrii rozdělení. Vodorovná příčka uprostřed nejmenšího obdélníku označuje medián, svislá úsečka na příčce odpovídá intervalu spolehlivosti mediánu.

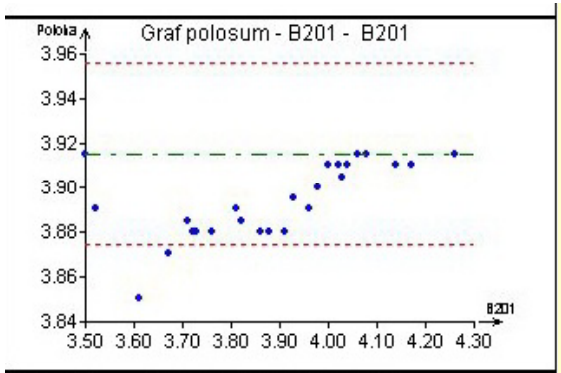

Graf polosum: většina bodů je v mezích a proto jde o symetrické rozdělení.

Citlivý indikátor asymetrie rozdělení. V ideálním případě leží body na horizontální přímce. Horizontální přímka, na níž leží poslední bod, představuje medián a červené přerušované meze jeho interval spolehlivosti. V případě asymetrického rozdělení vykazují body výrazný trend (rostoucí pro zápornou šikmost, nebo klesající, pro kladnou šikmost) výrazně překračující přerušované meze. Body jsou konstruovány ze dvojic dat (první, poslední; druhý, předposlední; atd.), proto označením bodu jsou označena dvě příslušná data v tabulce.

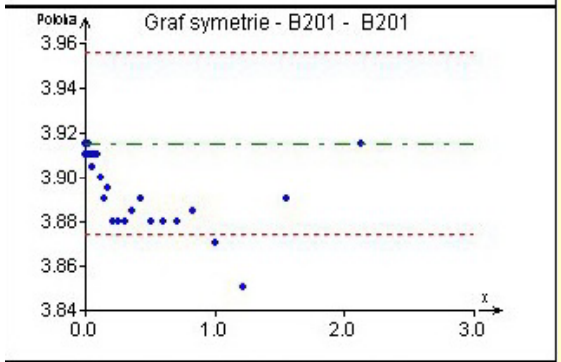

Graf symetrie: většina bodů je v mezích a proto jde o symetrické rozdělení.

Má podobný význam jako předchozí graf polosum. Směrnice případného trendu je úměrná šikmosti. V případě asymetrického rozdělení vykazují body výrazný trend (rostoucí pro zápornou šikmost, nebo klesající, pro kladnou šikmost) výrazně překračující přerušované meze. Body jsou konstruovány ze dvojic dat (první, poslední; druhý, předposlední; atd.), proto označením bodu jsou označena dvě příslušná data v tabulce.

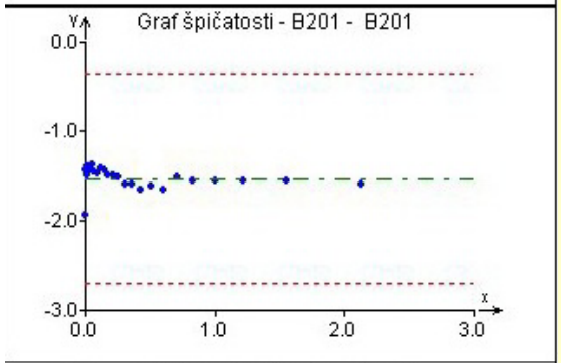

Graf špičatosti: většina bodů je v mezích a proto jde o symetrické rozdělení.

Má podobný význam jako dva předchozí grafy. Směrnice případného trendu je úměrná odchylky špičatosti od 3. V případě výrazně nenormální špičatosti rozdělení vykazují body výrazný trend. Body jsou konstruovány ze dvojic dat (první, poslední; druhý, předposlední; atd.), proto označením bodu jsou označena dvě příslušná data v tabulce.

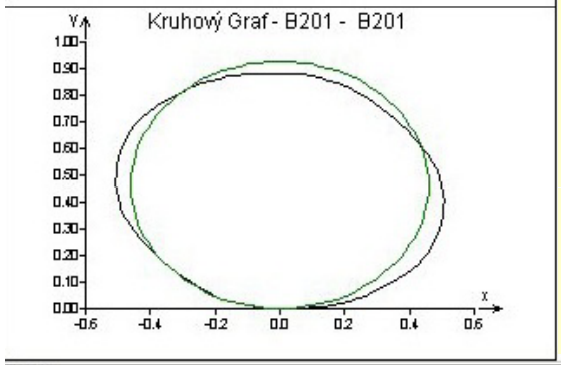

Kruhový graf: exp. elipsa se značně blíží teoretické pro normální rozdělení.

Slouží ke komplexnímu vizuálnímu posouzení normality na základě kombinace šikmosti a špičatosti. Zelený kruh (elipsa) je optimální tvar pro normální rozdělení, černý “kruh“ představuje data. V případě normálních dat se obě křivky téměř kryjí.

Základní analýza dat

Název úlohy :	B201
Data:	Všechna
Řád trendu :	4
Testovaná hodnota :	0
Vyhlazení hustoty :	0.5
Hladina významnosti :	0.05
Název sloupce :	B201
Počet platných dat :	50

Sloupec	Název sloupce.
Počet řádků	Celkový počet řádků v datech.
Počet platných dat	Celkový počet platných dat v datech.
Počet chybějících hodnot	Počet prázdných buněk v datech.

Klasické parametry :

Název sloupce :	B201
Průměr :	3.894
Spodní mez :	3.837588535
Horní mez :	3.950411465
Rozptyl :	0.0394
Směr. odchylka :	0.1984943324
Šikmost	-0.119116936
Odchylka od 0 :	Nevýznamná
Špičatost :	2.40159769
Odchylka od 3 :	Nevýznamná
Polosuma	3.915
Modus :	3.955352941

Klasické parametry

Aritmetický průměr	Odhad střední hodnoty pro normálně rozdělená data.
Spodní mez	Spodní mez intervalu spolehlivosti aritmetického průměru na zadané hladině významnosti.
Horní mez	Horní mez intervalu spolehlivosti aritmetického průměru na zadané hladině významnosti.
Rozptyl	Odhad rozptylu.
Směrodatná odchylka	Druhá odmocnina z rozptylu.
Šikmost	Odhad třetího statistického momentu, šikmosti.
Rozdíl od 0	Normální a každé symetrické rozdělení má šikmost nulovou. Je-li hodnota šikmosti statisticky významně odlišná od 0, nelze data považovat za symetrická. Spolehlivější je však test normality.
Špičatost	Odhad čtvrtého statistického momentu, špičatosti.
Rozdíl od 3	Normální rozdělení má špičatost 3. Je-li hodnota špičatosti statisticky významně odlišná od 3, lze předpokládat, že data neodpovídají nomálnímu rozdělelní. Spolehlivější je však test normality.
Polosuma	Odhad polosumy, tedy středu nejmenší a největší hodnoty.
Modus	Odhad modu rozdělení, tedy maxima na křivce hustoty pravděpodobnosti.

Robustní parametry :

Název sloupce :	B201
Medián :	3.915
IS spodní :	3.709937536
IS horní :	4.120062464
Medianová směr. odchylka :	0.1020426907
Medianový rozpty :	0.01041271072
10% Průměr :	3.895227273
10% IS spodní :	3.835978432
10% IS horní :	3.954476113
10% Směr. odchylka :	0.149154143
10% Rozptyl :	0.02224695837
20% Průměr :	3.897
20% IS spodní :	3.835649773
20% IS horní :	3.958350227
20% Směr. odchylka :	0.1243187477
20% Rozptyl :	0.01545515102
40% Průměr :	3.901666667
40% IS spodní :	3.838030654
40% IS horní :	3.96530268
40% Směr. odchylka :	0.08167506551
40% Rozptyl :	0.006670816327

Robustní parametry:

Medián	Odhad mediánu, tedy 50% kvantilu. Tento odhad střední hodnoty je spolehlivější než aritmetický průměr v případě porušení normality dat nebo přítomnosti vybočujících bodů.
IS spodní	Spodní mez intervalu spolehlivosti mediánu na zadané hladině významnosti.
IS horní	Horní mez intervalu spolehlivosti mediánu na zadané hladině významnosti.
Mediánová směr.odchylka	Odhad směrodatné odchylky na základě mediánu.
Mediánový rozptyl	Odhad rozptylu na základě mediánu.
10% uřezaný průměr	Aritmetický průměr pro symetrickém uřezání 10% dat, tedy 5% nejmenších a 5% největších hodnot. Tento robustní odhad střední hodnoty se doporučuje v případě podezření na vybočující body.
IS spodní	Spodní mez intervalu spolehlivosti uřezaného průměru na zadané hladině významnosti.
IS horní	Horní mez intervalu spolehlivosti uřezaného průměru na zadané hladině významnosti.
Rozptyl	Odhad rozptylu na zálkladě mediánu.
Směr. odchylka	Odhad směrodatné odchylky na základě mediánu.
¨40% uřezaný průměr	Aritmetický průměr pro symetrickém uřezání 40% dat, tedy 20% nejmenších a 20% největších hodnot. Tento robustní odhad střední hodnoty se doporučuje v případě podezření na velký počet vybočujících bodů.
IS spodní	Spodní mez intervalu spolehlivosti uřezaného průměru na zadané hladině významnosti.
IS horní	Horní mez intervalu spolehlivosti uřezaného průměru na zadané hladině významnosti.
Rozptyl	Odhad rozptylu na zálkladě mediánu.
Směr. odchylka	Odhad směrodatné odchylky na základě mediánu.

Znaménkový test :	
Závěr :	Data jsou nezávislá

Test normality :	
Název sloupce :	B201
Průměr :	3.894
Rozptyl :	0.0394
Šikmost	-0.119116936
Špičatost :	2.40159769
Normalita :	Přijata
Vypočtený :	0.2378781079
Teoretický :	5.991464547
Pravděpodobnost :	0.8878619108

Vybočující body :	
Název sloupce :	B201
Homogenita :	Přijata
Počet vybočujících bodů :	0
Spodní mez :	3.04482
Horní mez :	4.70518

Znaménkový test Neparametrický test nezávislosti dat, závislost je indikována, obsahují-li data shluky po sobě jdoucích sekvencí se shodným znaménkem odchylky od průměru.

Závěr Slovní závěr testu zavislosti dat.

Test normality Kombinovaný test normality založený na shodě šikmosti a špičatosti s normálním rozdělením.

Normalita Slovní závěr testu na zadané hladině významnosti.

Vypočtený Vypočtená testovací statistika.

Teoretický Příslušný kvantil t-rozdělení.

Pravděpodobnost Pravděpodobnost odpovídající vypočtené statistice.

Vybočující body Robustní test na přítomnost vybočujících měření založený na kvantilovém odhadu vnitřních mezí dat.

Homogenita Slovní závěr testu, nejsou-li v datech vybočující měření, je předpoklad homogenity přijat.

Počet vybočujících bodů Počet případných měření přesahujících přípustné meze, které je možno považovat za vybočující.

Dolní hranice Dolní hranice, pod níž je možno data považovat za vybočující.

Horní hranice Horní hranice, nad níž je možno data považovat za vybočující.

Autokorelace :	
Řád autokorelace :	4
Název sloupce :	B201
Počet :	0.0521889568
Řád autokorelace 1	
Korelační koeficient :	0.01257847301
Pravděpodobnost :	0.4658208006
Závěr :	Nevýznamný
Řád autokorelace 2	
Korelační koeficient :	-0.1020884699
Pravděpodobnost :	0.2449546948
Závěr :	Nevýznamný
Řád autokorelace 3	
Korelační koeficient :	-0.02901067026
Pravděpodobnost :	0.4232554223
Závěr :	Nevýznamný
Řád autokorelace 4	
Korelační koeficient :	0.0521889568
Pravděpodobnost :	0.3652515549
Závěr :	Nevýznamný
Test významnosti trendu :	
Název sloupce :	B201
Směrnice :	0.0004225690276
Významnost :	Nevýznamný
Pravděpodobnost :	0.5847032011

Autokorelace Odhady autokorelačních koeficientů a jejich významnost na zadané hladině významnosti.

Řád autokorelace Řád autokorelace.

Koeficient Hodnota autokorelačního koeficientu, formálně odpovídá párovému korelačnímu koeficientu a má stejné vlastnosti.

Pravděpodobnost Pravděpodobnost nevýznamnosti autokorelační-ho koeficientu; je-li menší než zvolená hladina významnosti, je autokorelace významná.

R0Krit Kritická hodnota autokorelačního koeficientu, nad níž se korelace považuje za významnou.

Vysledek Slovní vyjádření významnosti autokorelace.

Vyhlazené hodnoty Hodnoty klouzavých průměrů a mediánů. Při vhodné volbě řádu trendu lze získat po odečtení těchto hodnot od vstupních dat detrendovaná data, která lze použít pro konstrukci regulačních diagramů v případě, že je v datech příliš silný trend.

Rezidua Odchylky (rozdíly) naměřených a vyhlazených hodnot, (nameřená - vyhlazená).

Test významnosti trendu Test významnosti lineárního trendu v datech.

Vypočtený Testovací statistika pro směrnici přímky vypočtená z dat.

Teoretický Příslušný kvantil t-rozdělení.

Trend Hodnota směrnice přímky proložené daty

Pravděpodobnost Pravěpodobnost toho, že je lineární trend nevýznamný; vyjde-li menší než zadaná hladina významnosti (tedy obvykle 0.05), považuje se trend za významný.

2. Ověření předpokladů výběru dat:

Diagnosticky, testy: *ověření normality*

ověření nezávislosti

ověření homogenity

určení minimální četnosti

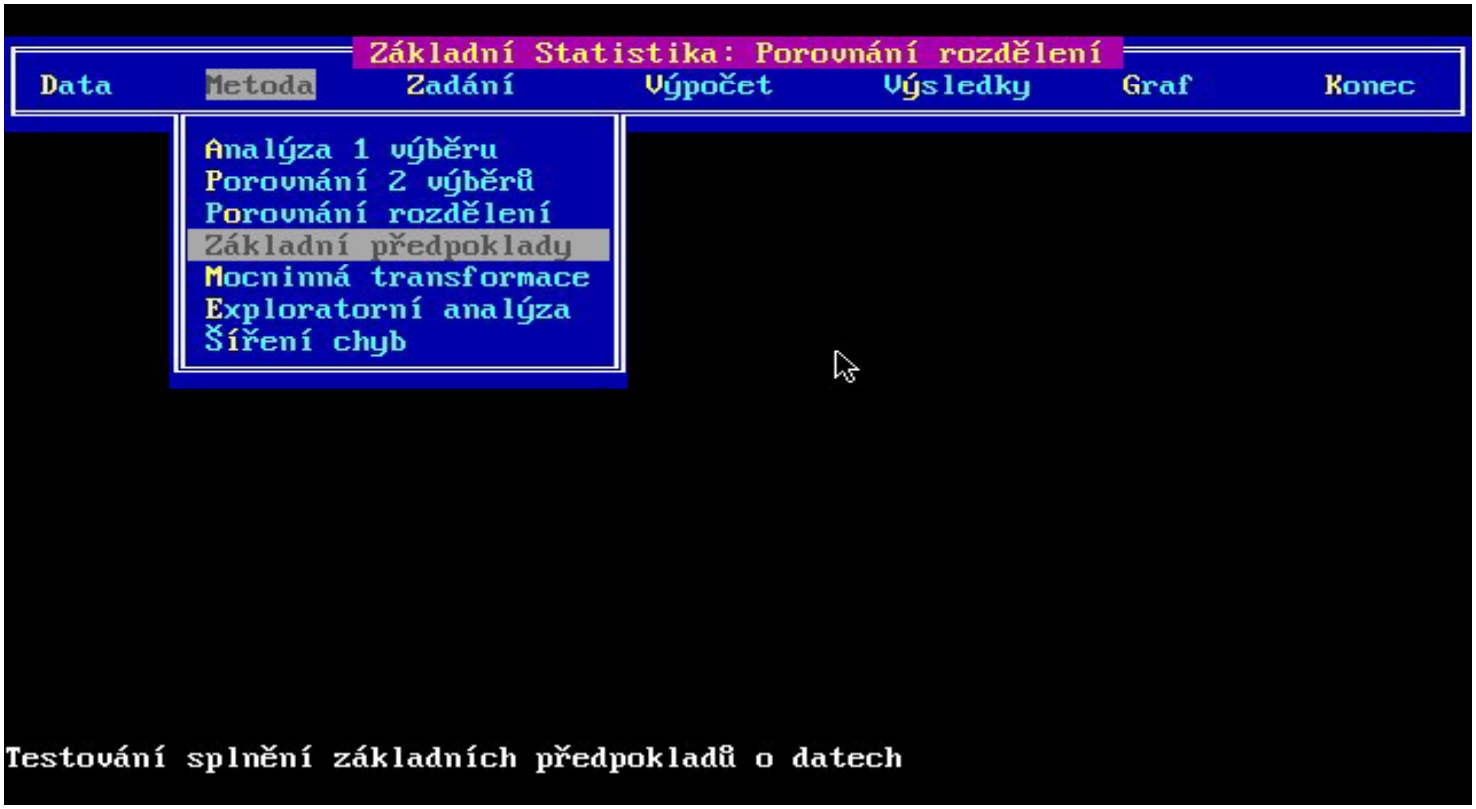

```
V Ý S L E D K Y

                    ZÁKLADNÍ STATISTIKA

                    Základní předpoklady

Název : B201

                          V S T U P

(1) DATA A PODMÍNKY:
    Počet dat                  : 50
    Hladina významnosti alfa   : 0.050
    Název výstupního souboru   : RESULTS.TXT

(2) VSTUPNÍ DATA:

 (  1)  3.8600E+00 ( 14) 4.0400E+00 ( 27) 4.0200E+00 ( 40) 4.0200E+00
 (  2)  4.0600E+00 ( 15) 3.9300E+00 ( 28) 3.8200E+00 ( 41) 4.0800E+00
 (  3)  3.6700E+00 ( 16) 4.1400E+00 ( 29) 3.6200E+00 ( 42) 4.0400E+00
Napověda-F1   Řádek: 1 - 23                Celkem: 81    Délka: 2739
```

Data a podmínky výpočtu.

```
V Ý S L E D K Y

    Aritmetický průměr :  3.8940E+00
    Rozptyl            :  3.9398E-02
    Směrodatná odchylka:  1.9849E-01

    Vnitřní meze:
    Spodní mez :  3.0764E+00
    Horní mez  :  4.6837E+00

(4) MINIMÁLNÍ VELIKOST VÝBĚRU:

    pro 25% relativní chybu směrodatné odchylky : n = 7
    pro 10% relativní chybu směrodatné odchylky : n = 36
    pro  5% relativní chybu směrodatné odchylky : n = 141

(5) DETEKCE ODLEHLÝCH BODŮ:

    Ve výběru nejsou odlehlé body

    Parametry s vynechanými odlehlými hodnotami:
    Průměr             :  3.8940E+00     Rozptyl  :  3.9398E-02
    Směrodatná odchylka:  1.9849E-01     Šikmost  : -1.1915E-01
    Špičatost          :  2.4016E+00
Napověda-F1   Řádek: 60 - 81               Celkem: 81    Délka: 2739
```

V datech nejsou outliery.

```
V Ý S L E D K Y

(1) KLASICKÉ ODHADY PARAMETRŮ:

    Průměr             :  3.8940E+00     Rozptyl  :  3.9398E-02
    Směrodatná odchylka:  1.9849E-01     Šikmost  : -1.1890E-01
    Špičatost          :  2.4015E+00

(2) TEST NORMALITY:

    Tabulkový kvantil  Chi^2(1-alfa,2) :  5.9915E+00
    Chi^2-statistika                   :  7.0013E-01
        Závěr: Předpoklad normality přijat
    Vypočtená hladina významnosti      :  6.7701E-01

(3) TEST NEZÁVISLOSTI:

    Tabulkový kvantil  t(1-alfa/2,n+1) :  2.0076E+00
    Test autokorelace                  :  2.9905E-01
        Závěr: Předpoklad nezávislosti přijat
    Vypočtená hladina významnosti      :  3.8306E-01

    Předpoklad homogenity výběru:
Napověda-F1   Řádek: 37 - 59               Celkem: 81    Délka: 2739
```

Data jsou normálního rozdělení.

Data jsou nezávislá.

Data jsou homogenní.

Závěr Základních předpokladů:

Data vykazují Gaussovo normální rozdělení a není proto třeba použít jakoukoliv transformaci dat.

Test prokázal, že data jsou nezávislá a bez vybočujících hodnot.

Základní Statistika: Porovnání rozdělení

Data Metoda Zadání Výpočet Výsledky Graf Konec

Analýza 1 výběru
Porovnání 2 výběrů
Porovnání rozdělení
Základní předpoklady
Mocninná transformace
Exploratorní analýza
Šíření chyb

Určení typu rozdělení výběru.

Srovnej výběr s 11 teoretickými rozděleními

Základní Statistika: Porovnání rozdělení

Data Metoda Zadání Výpočet Výsledky Graf Konec

Podmínky
Volby

V O L B Y

Kreslit Q-Q graf : Kreslit TDF graf : Ano
Hladina významnosti: 0.050

Název výst. souboru: RESULTS .TXT

Data a podmínky výpočtu.

Zadej počáteční volby

Č E K Á M ...

Základní Statistika: Porovnání rozdělení

Data Metoda Zadání Výpočet Výsledky Graf Konec

Podmínky
Volby

P O D M Í N K Y V Ý P O Č T U

Název: B201

Počáteční podmínky:

Data a podmínky výpočtu.

Parametr pro Weibullovo rozd.: 1.0000E+00
Parametr for Paretovo rozděl.: 1.0000E+00
Parametr pro Gamma rozdělení : 1.0000E+00

Zadej podmínky pro výpočet

V Ý S L E D K Y

ZÁKLADNÍ STATISTIKA

Porovnání rozdělení

Název : B201

Data a podmínky výpočtu.

V S T U P

(1) DATA A PODMÍNKY:
Počet dat : 50
Hladina významnosti alfa : 0.050
Název výstupního souboru : RESULTS.TXT

(2) VSTUPNÍ DATA:

(1)	3.8600E+00	(14)	4.0400E+00	(27)	4.0200E+00	(40)	4.0200E+00
(2)	4.0600E+00	(15)	3.9300E+00	(28)	3.8200E+00	(41)	4.0800E+00
(3)	3.6700E+00	(16)	4.1400E+00	(29)	3.6200E+00	(42)	4.0400E+00
(4)	3.9700E+00	(17)	3.8800E+00	(30)	3.6800E+00	(43)	3.7800E+00

Napověda-F1 Řádek: 1 - 23 Celkem: 158 Délka: 8464

V Ý S L E D K Y

(1) LINEARITA V GRAFU KVANTIL-KVANTIL (Q-Q):

Čís.	Rozdělení	Směrnice	Úsek	Korelační koeficient
0	Laplaceovo	1.4496E-01	3.8940E+00	9.7403E-01
1	Normální	2.0124E-01	3.8940E+00	9.9432E-01
2	Exponenciální	1.8826E-01	3.7087E+00	8.9901E-01
3	Rovnoměrné	6.7467E-01	3.5567E+00	9.8601E-01
4	Lognormální	9.4522E-02	3.7446E+00	8.2336E-01
5	Gumbelovo	1.5654E-01	3.9824E+00	9.7451E-01
6	Weibullovo(2.0)	4.2672E-01	3.5171E+00	9.8026E-01
6	Weibullovo(2.5)	5.2410E-01	3.4298E+00	9.8961E-01
6	Weibullovo(3.0)	6.1507E-01	3.3452E+00	9.9358E-01
6	Weibullovo(3.5)	7.0227E-01	3.2623E+00	9.9511E-01
6	Weibullovo(4.0)	7.8709E-01	3.1806E+00	9.9546E-01
6	Weibullovo(4.5)	8.7035E-01	3.0996E+00	9.9523E-01
6	Weibullovo(5.0)	9.5252E-01	3.0191E+00	9.9470E-01
6	Weibullovo(5.5)	1.0339E+00	2.9390E+00	9.9404E-01
6	Weibullovo(6.0)	1.1147E+00	2.8593E+00	9.9332E-01
6	Weibullovo(6.5)	1.1951E+00	2.7798E+00	9.9259E-01

Sleduje se nejvyšší hodnota korelačního koeficientu blízká 1, a to pro prvních 5 rozdělení.

Napověda-F1 Řádek: 36 - 58 Celkem: 158 Délka: 8464

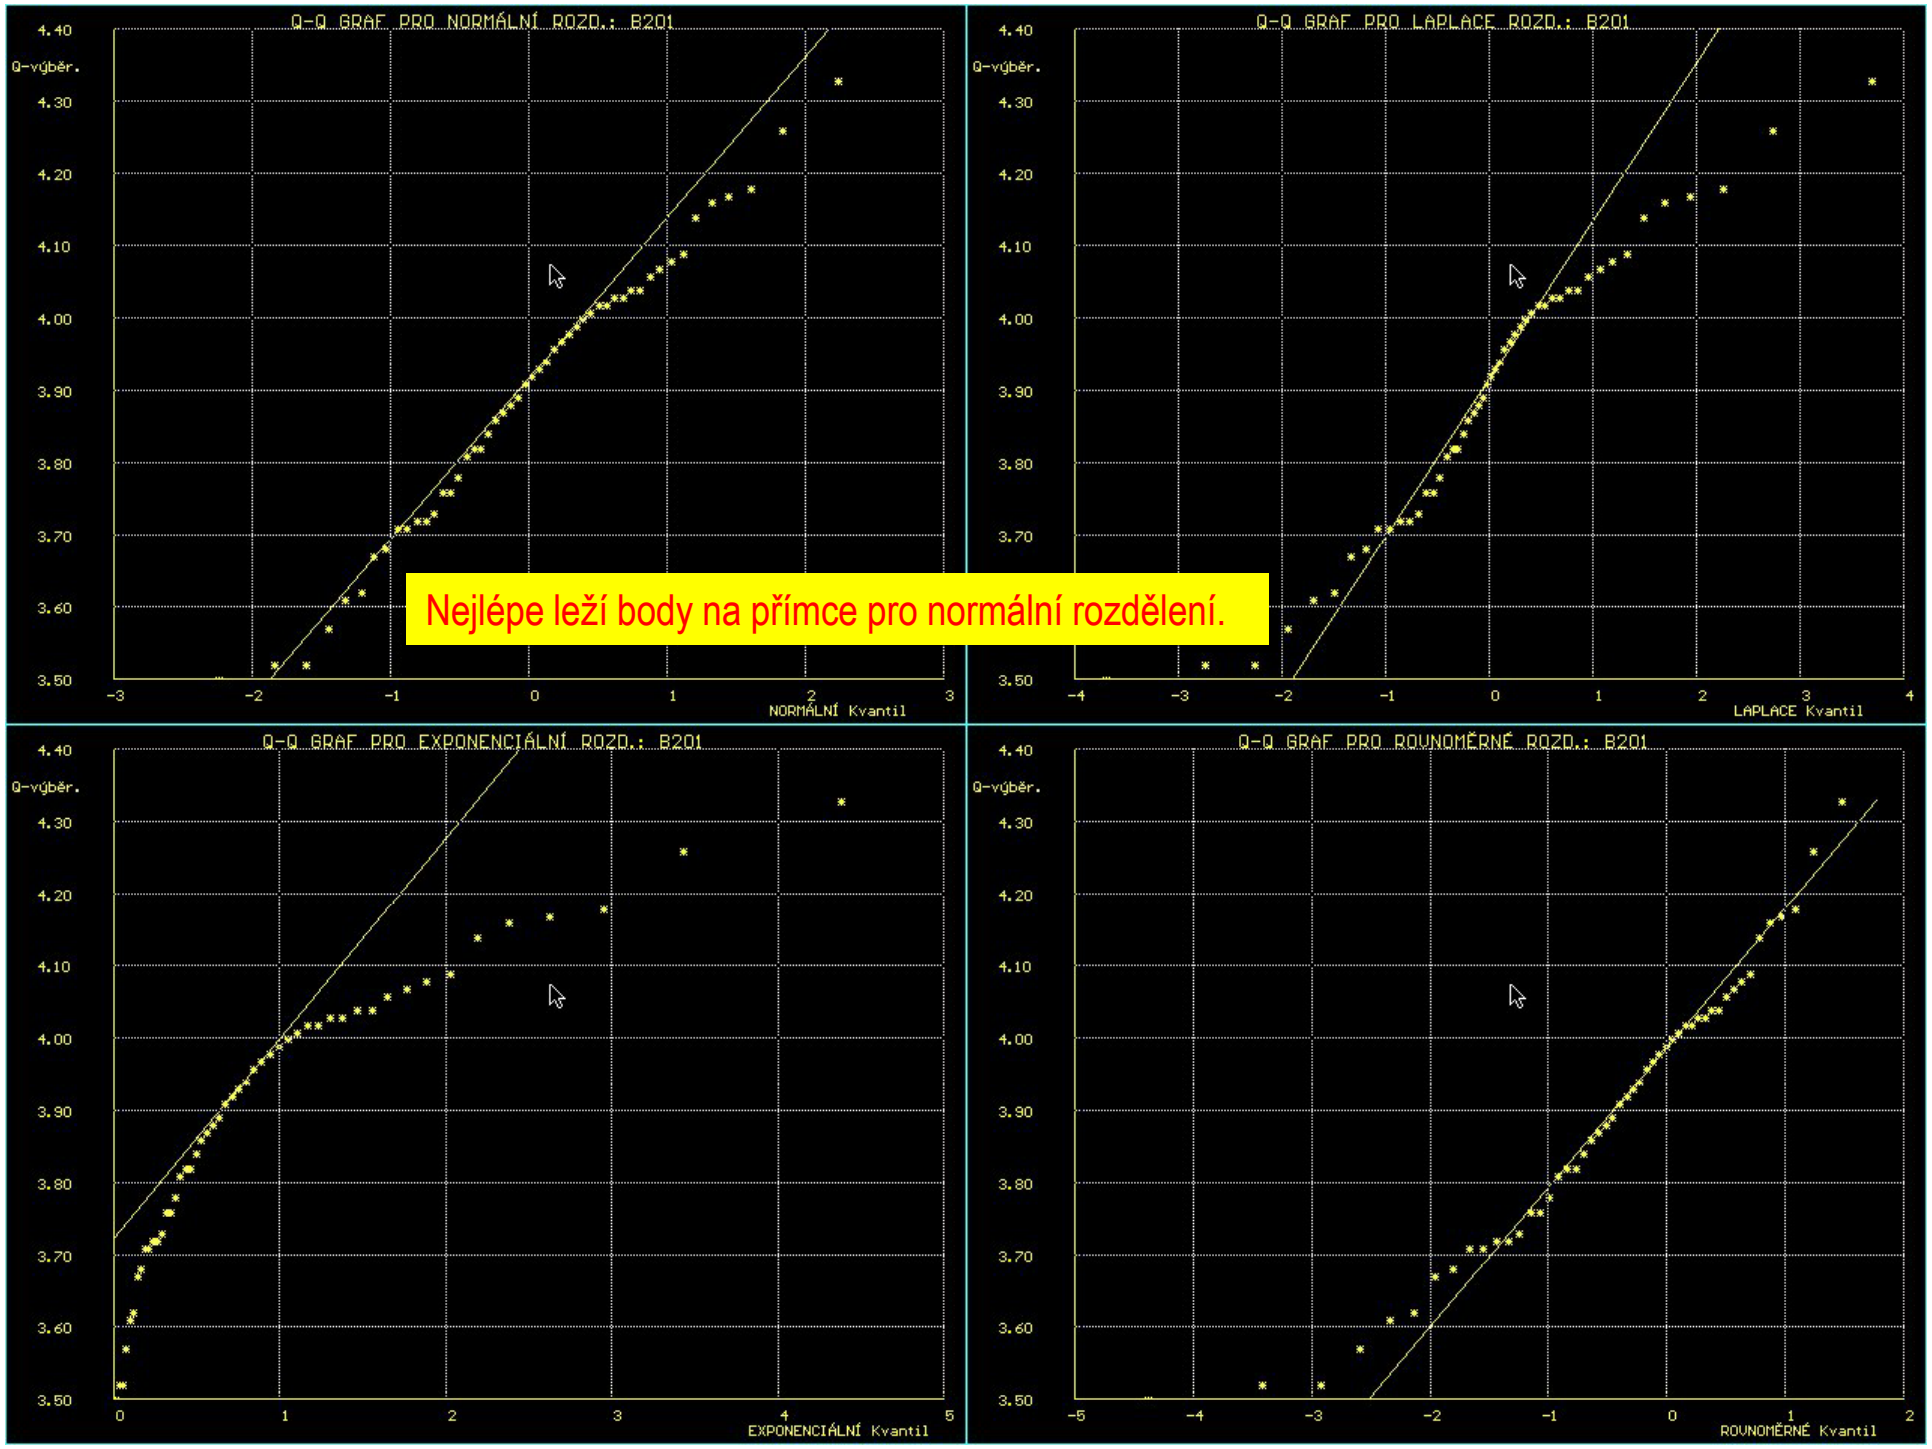

Nejlépe leží body na přímce pro normální rozdělení.

3. Transformace dat:

Analýza dat: *originální data*

data po mocninné transformaci

data po Box-Coxově transformaci

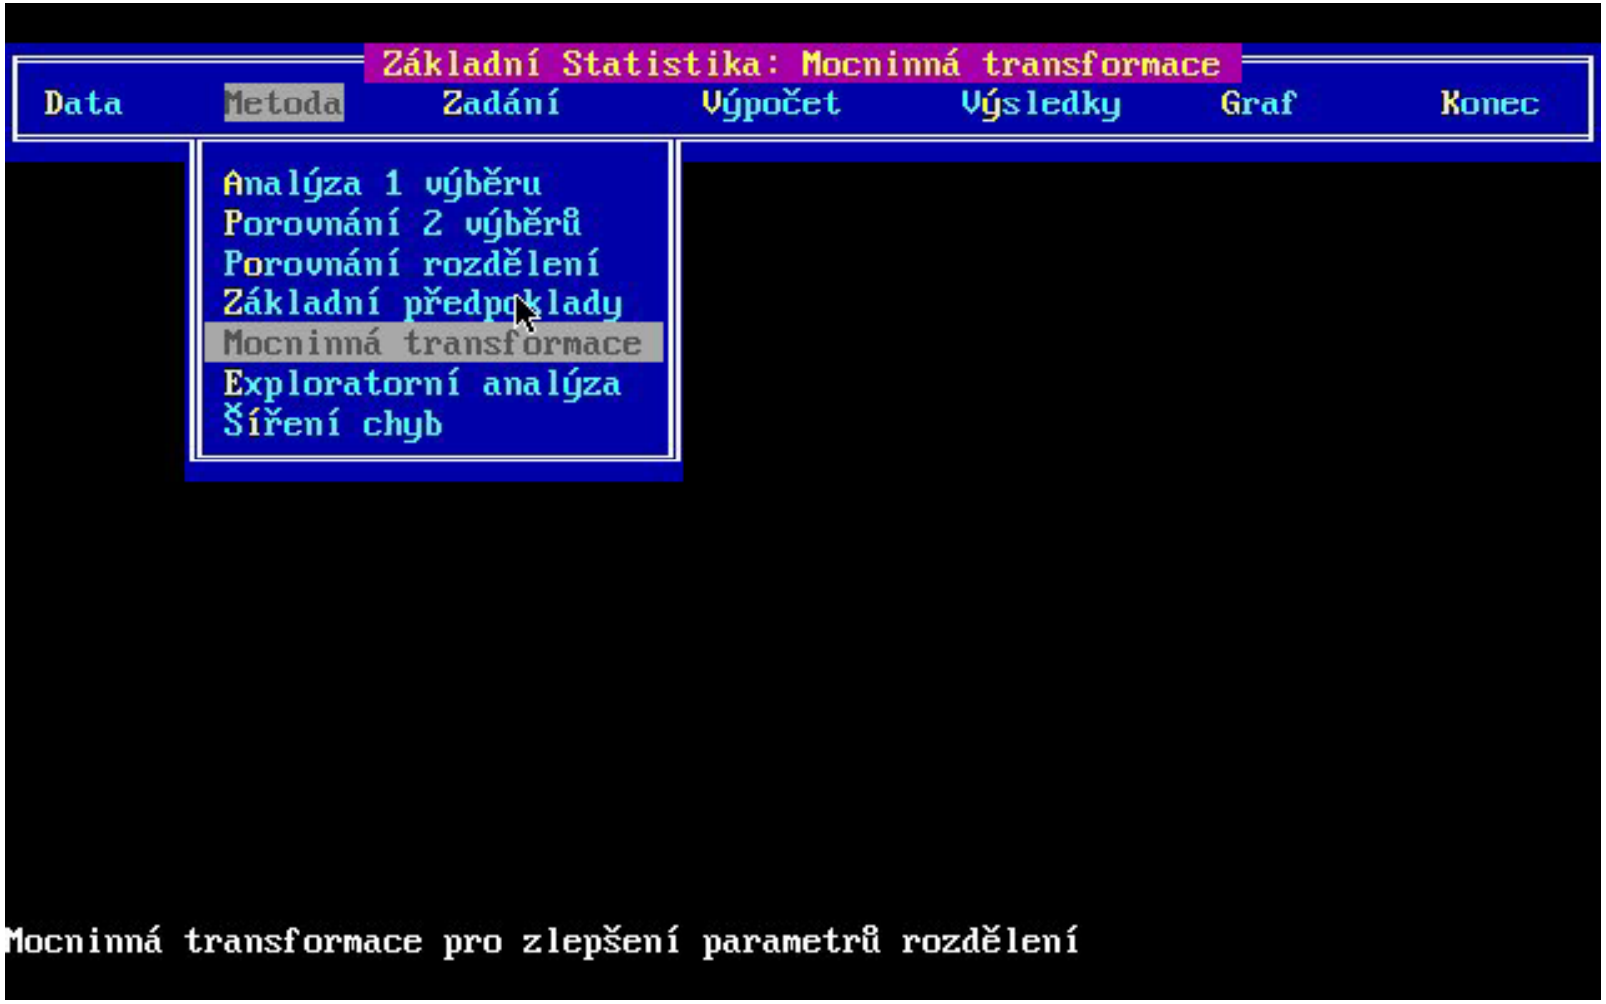

```
Č E K Á M ...
Základní Statistika: Mocninná transformace
Data    Metoda    Zadání    Výpočet    Výsledky    Graf    Konec
                  Podmínky
                  Volby

P O D M Í N K Y   V Ý P O Č T U

        Název: B201

Prostá mocnina   :  5.0000E-01      Box - Coxova mocnina :  5.0000E-01

Zadej podmínky pro výpočet
```

```
V Ý S L E D K Y

                    ZÁKLADNÍ STATISTIKA

                    MOCNINNÁ TRANSFORMACE

 Název : B201

                          V S T U P

 (1) DATA A PODMÍNKY:
     Počet dat                  : 50
     Hladina významnosti alfa   : 0.050
     Název výstupního souboru   : RESULTS.TXT

 (2) VSTUPNÍ DATA:

  (  1)  3.8600E+00 ( 14) 4.0400E+00 ( 27) 4.0200E+00 ( 40) 4.0200E+00
  (  2)  4.0600E+00 ( 15) 3.9300E+00 ( 28) 3.8200E+00 ( 41) 4.0800E+00
  (  3)  3.6700E+00 ( 16) 4.1400E+00 ( 29) 3.6200E+00 ( 42) 4.0400E+00
  (  4)  3.9700E+00 ( 17) 3.8800E+00 ( 30) 3.6800E+00 ( 43) 3.7800E+00
Napověda-F1   Řádek: 1 - 23                Celkem: 185   Délka: 7564
```

```
V Ý S L E D K Y

(2) PROSTÁ MOCNINNÁ TRANSFORMACE:

(A) Optimální hodnoty mocniny pro vybraná kritéria:

    Optimální mocnina: 2.1333E+00 pro šikmost          : 1.1508E-03
    Optimální mocnina:-4.0000E+00 pro špičatost        : 3.3114E+00
    Optimální mocnina: 4.0000E+00 pro asymetrii        : 7.4458E-03
    Optimální mocnina: 4.0000E+00 pro asymetrii, rob.  : 1.7341E-01
    Optimální mocnina:-4.0000E+00 pro Hinkley-asymetrii: 7.1361E-04

    Zvolená mocnina  : 2.13

        Průměr             :  1.8232E+01
        Rozptyl            :  3.8861E+00
        Směrodatná odchylka :  1.9713E+00
        Šikmost            :  1.1508E-03
        Špičatost          :  2.4333E+00
        Opravený průměr    :  3.8996E+00

(B) Kvantilové míry:

   Kvantil   P      Spodní mez   Horní mez    Polorozptyl
Napověda-F1   Řádek: 63 - 85               Celkem: 185   Délka: 7564
```

```
V Ý S L E D K Y

(3) BOX-COXOVA TRANSFORMACE:

(A) Optimální hodnoty mocniny pro vybraná kritéria:

    Optimální mocnina: 2.1333E+00 pro šikmost          : 1.1508E-03
    Optimální mocnina:-4.0000E+00 pro špičatost        : 3.3114E+00
    Optimální mocnina: 4.0000E+00 pro asymetrii        : 7.4458E-03
    Optimální mocnina: 4.0000E+00 pro asymetrii, rob.  : 1.7341E-01
    Optimální mocnina:-4.0000E+00 pro Hinkley-asymetrii: 1.7840E-04
    Optimální mocnina: 2.0000E+00 pro věrohodnost      : 8.0914E+01

    Zvolená mocnina  : 2.13

        Průměr             :  8.0777E+00
        Rozptyl            :  8.5387E-01
        Směrodatná odchylka :  9.2405E-01
        Šikmost            :  1.1508E-03
        Špičatost          :  2.4333E+00
        Opravený průměr    :  3.8996E+00

(B) Kvantilové míry:
Napověda-F1   Řádek: 96 - 118              Celkem: 185   Délka: 7564
```

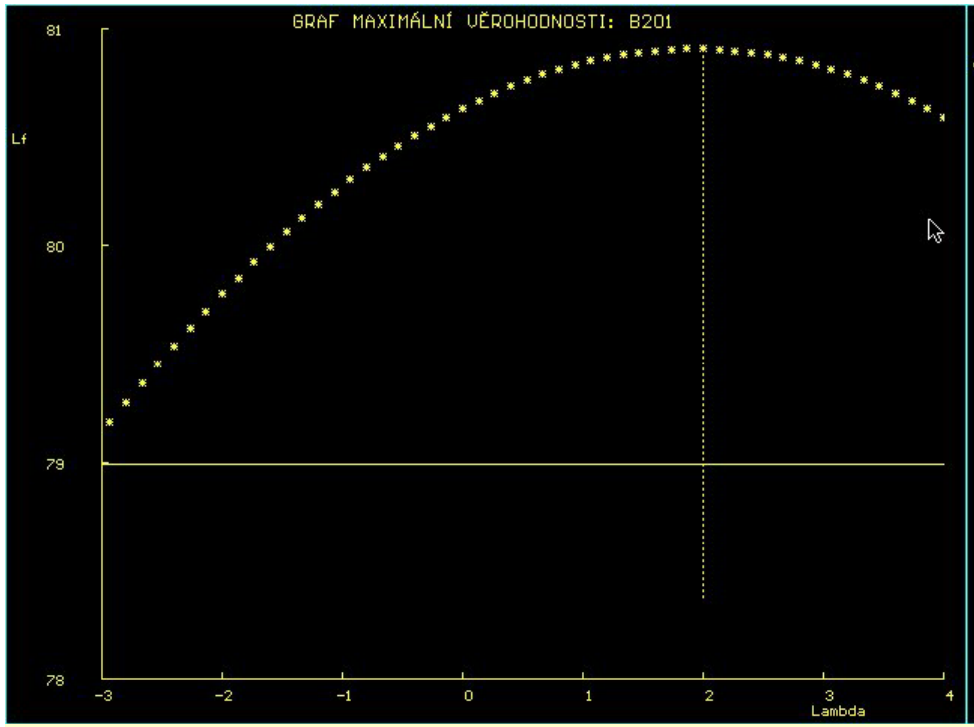

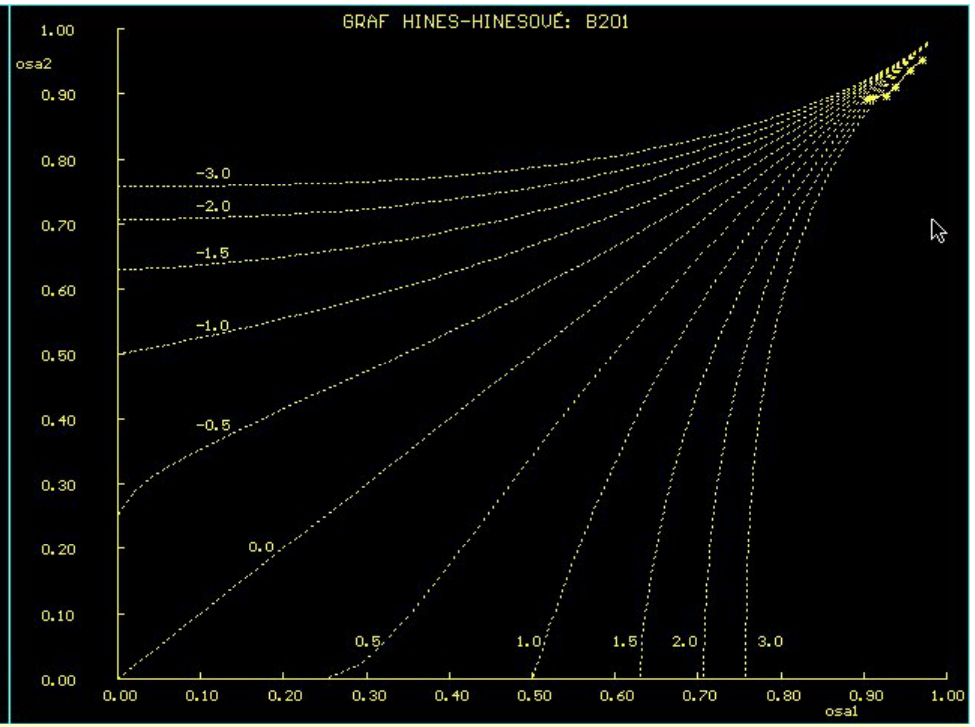

Rozhodčí kritérium použití transformace dat:

Nachází-li se pod segmentem na x-ové ose číslo 1 , pak je transformace zbytečná a lze využít pro odhad střední hodnoty aritmetický průměr.

Závěr: Jelikož zde je číslo 1 pod segmentem, je ze statistického hlediska retransformovaný průměr shodný s aritmetickým.

Určení nejlepšího odhadu exponentu lambda Grafickou metodou grafem Hinese a Hinesové:

V nomogramu Hines-Hines se odhadne poloha křivky s body, která se přibližuje některému průvodiči v nomogramu.

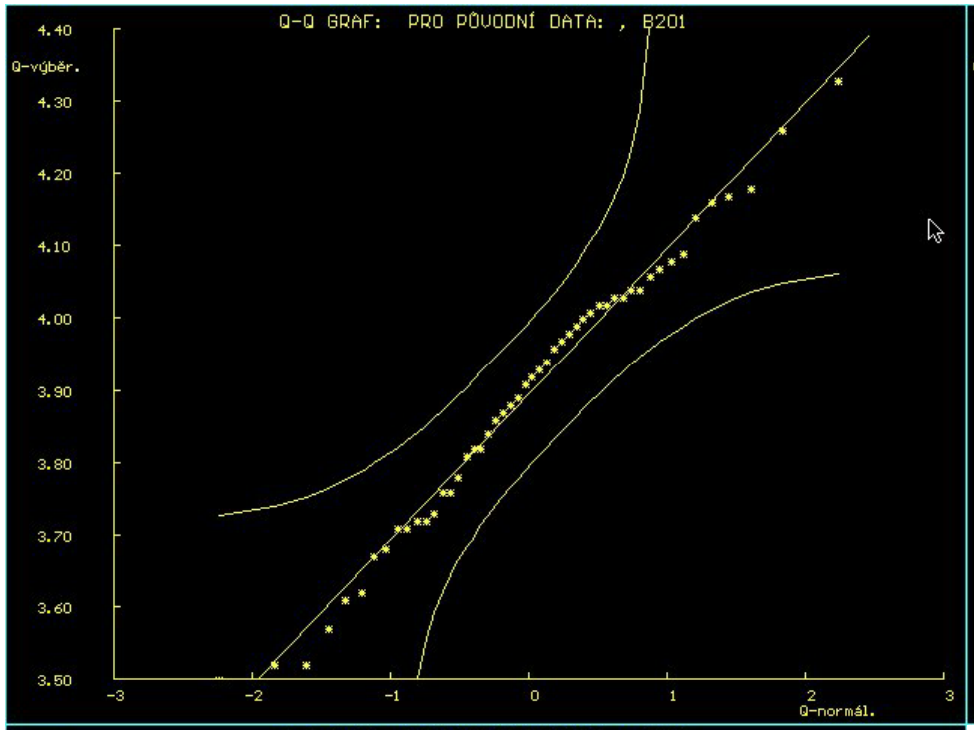

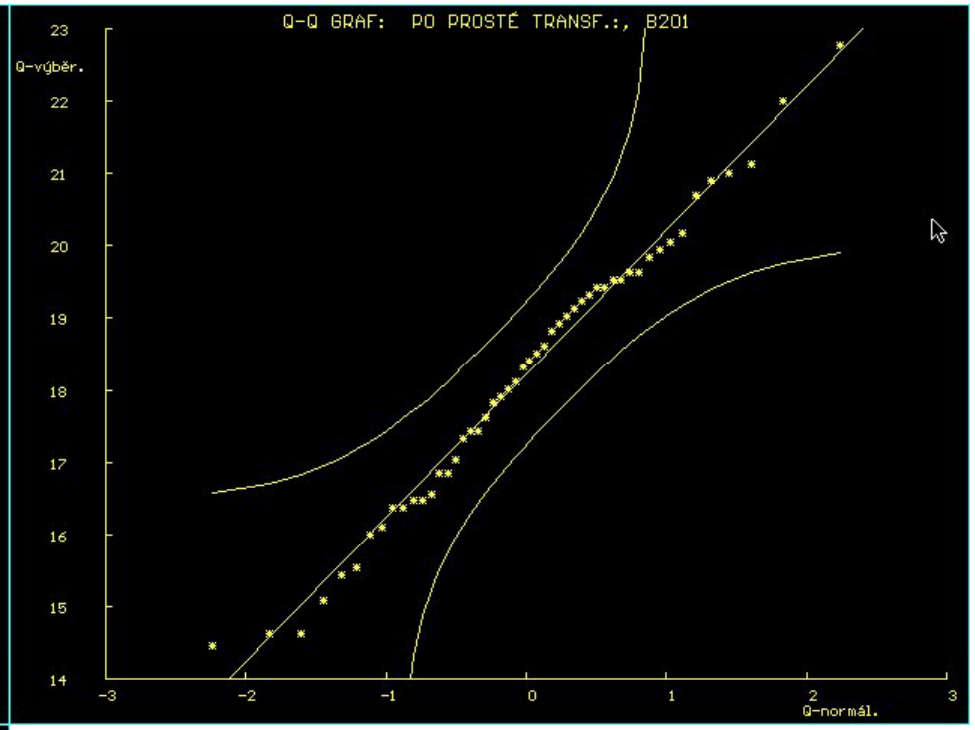

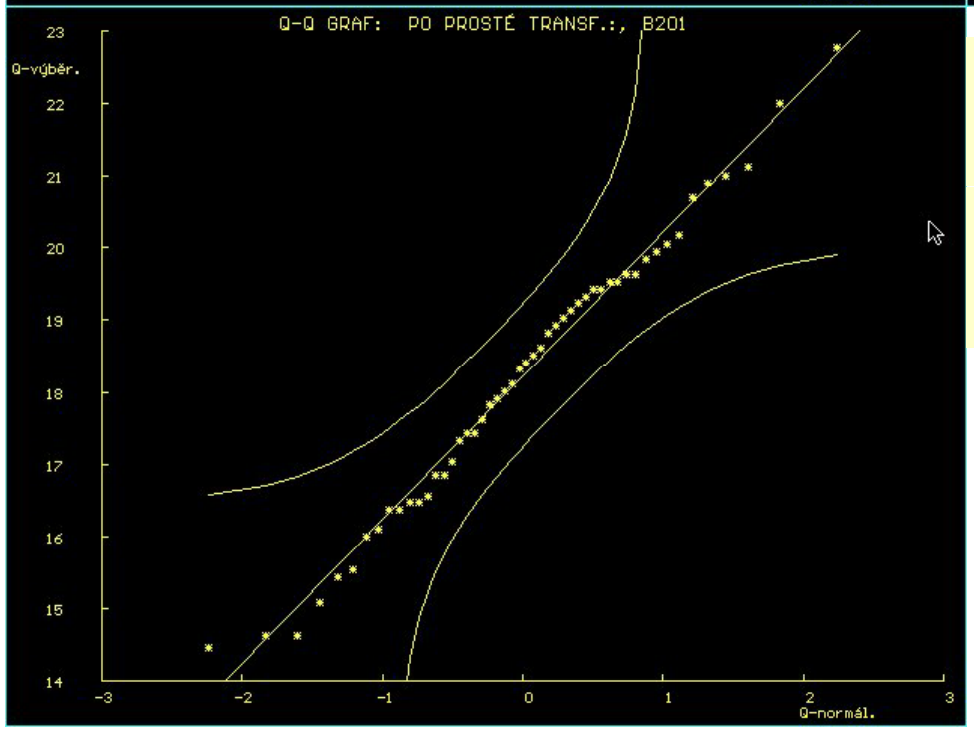

Ukázka postupného zlepšení symetrie rozdělení po transformaci dat.

Symetrie je indikovaná v Q-Q kvantil-kvantilovém grafu.

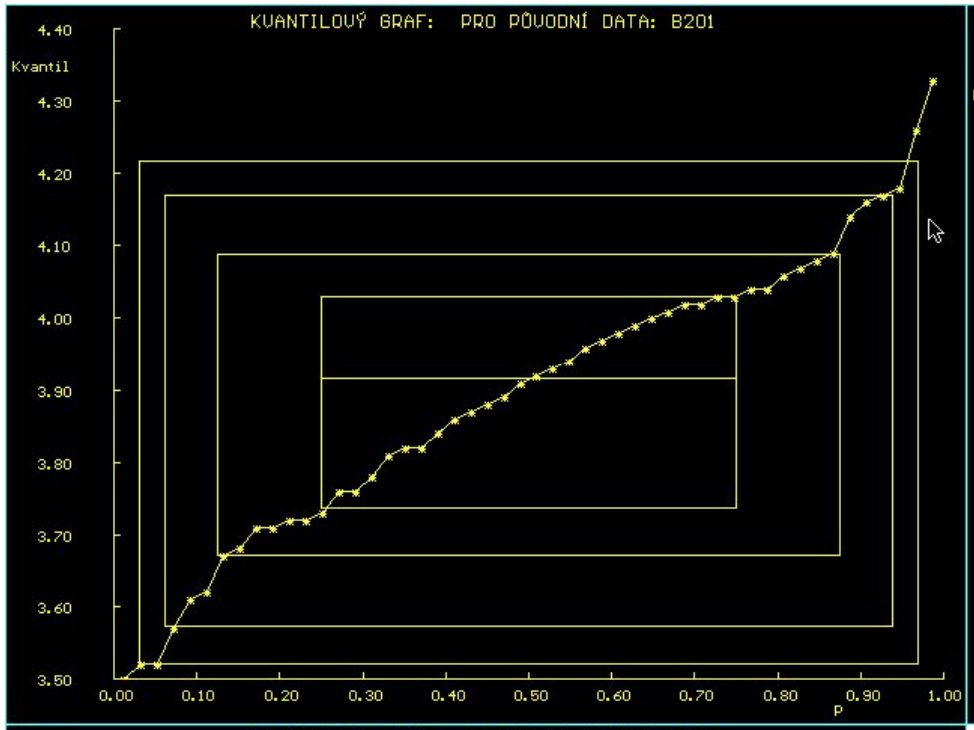

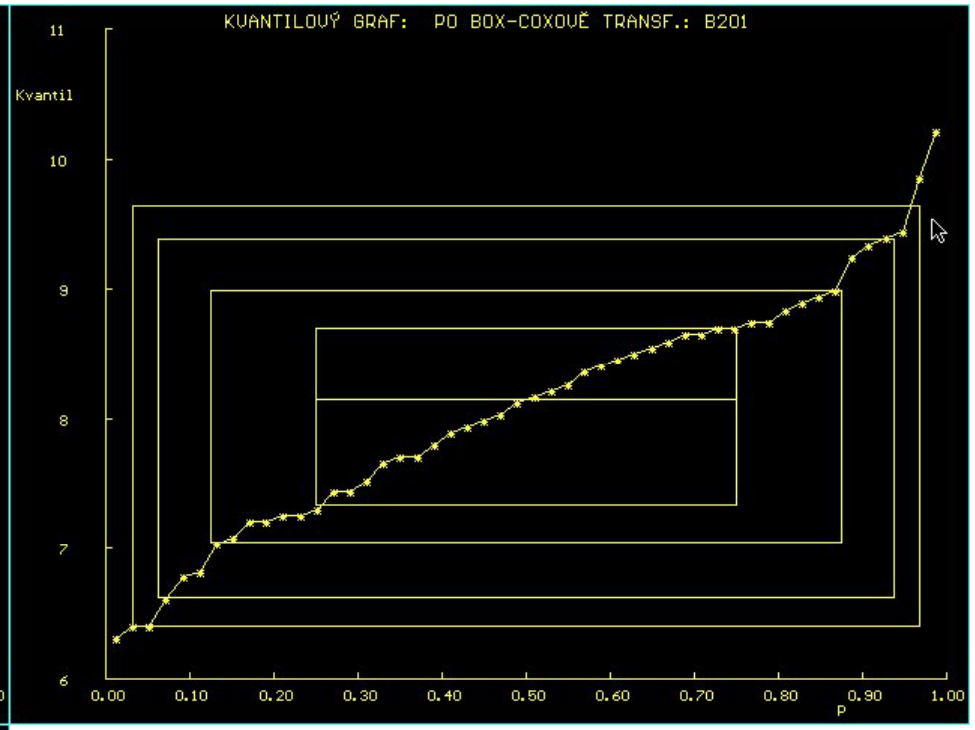

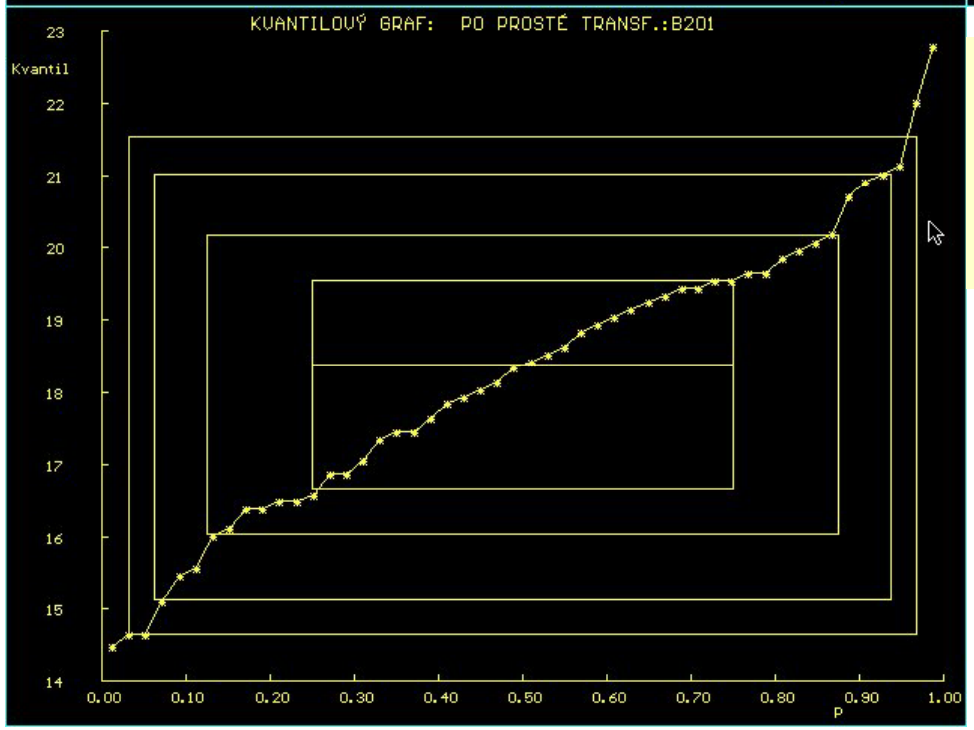

Ukázka postupného zlepšení symetrie rozdělení po transformaci dat.

Symetrie je indikovaná v grafu rozptýlení s kvantily.

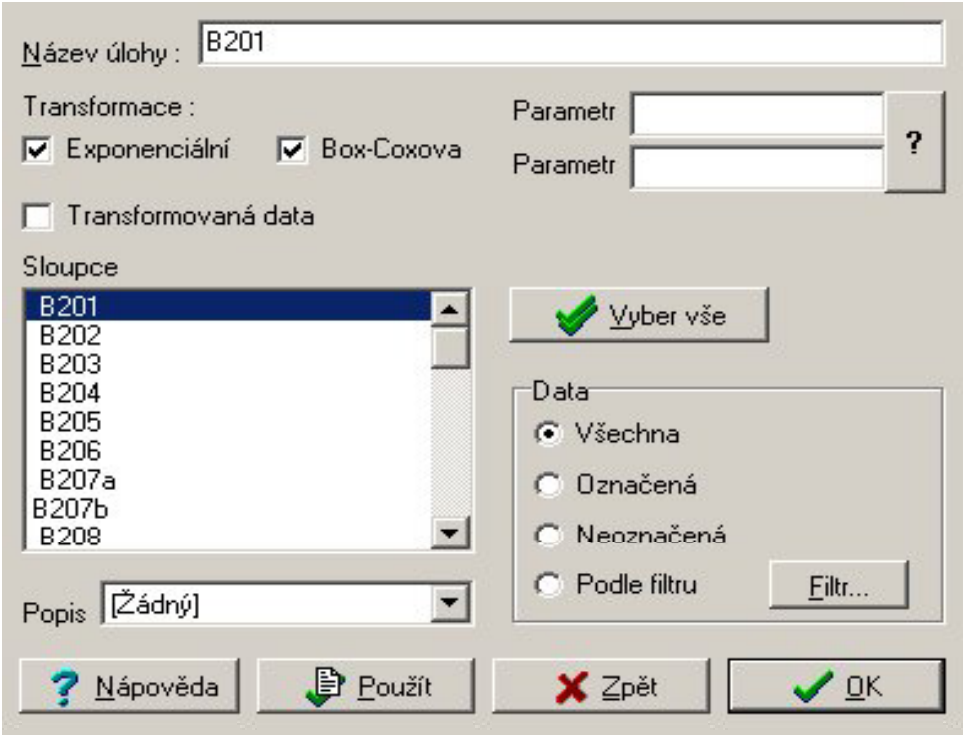
Název úlohy : B201
Transformace :
Exponenciální
Box-Coxova
Parametr
Parametr
?
Transformovaná data
Sloupce
B201
B202
B203
B204
B205
B206
B207a
B207b
B208
Vyber vše
Data
Všechna
Označená
Neoznačená
Podle filtru
Filtr...
Popis
[Žádný]
Nápověda
Použít
Zpět
OK

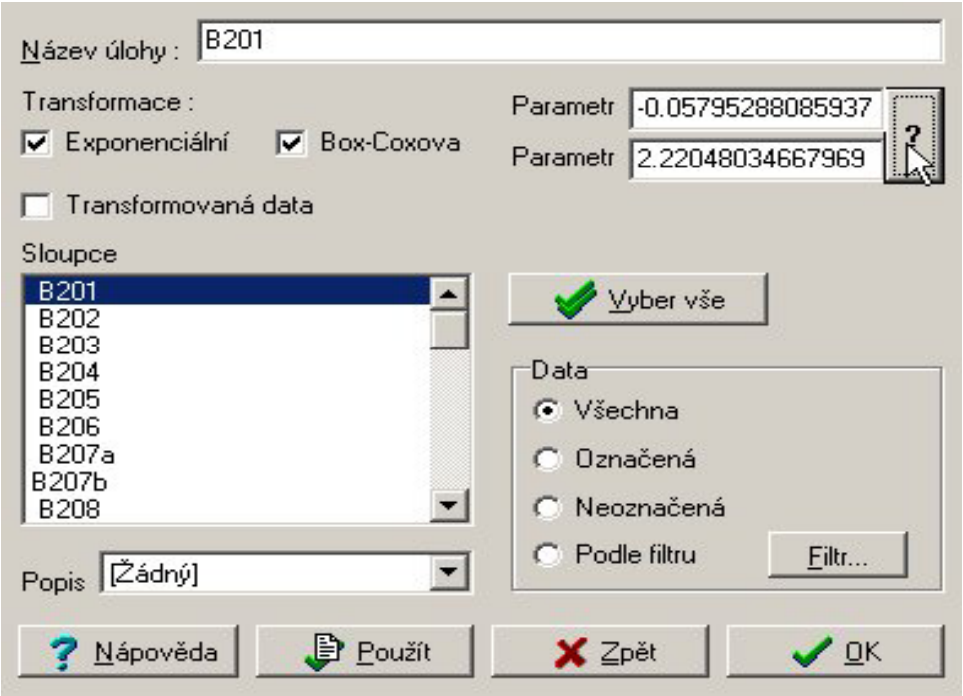
Název úlohy : B201
Transformace :
Exponenciální
Box-Coxova
Parametr -0.05795288085937
Parametr 2.22048034667969
?
Transformovaná data
Sloupce
B201
B202
B203
B204
B205
B206
B207a
B207b
B208
Vyber vše
Data
Všechna
Označená
Neoznačená
Podle filtru
Filtr...
Popis
[Žádný]
Nápověda
Použít
Zpět
OK

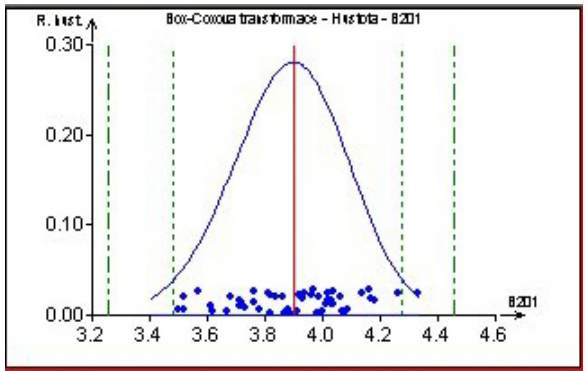

Graf hustoty představuje tvar rozdělení, který nejlépe vystihuje data prostředky Box-Coxovy transformace. Svislé čáry představují kvantily (hodnoty) odpovídající (od středu) mediánu (50% kvantil), kvartilu (25% kvantily ohraničující 50% dat), ±2s (zhruba 2.5% kvantily ohraničující interval 95% dat), 0.5% kvantily ohraničující 99% dat a ±3s (ohraničující 99.73% dat).

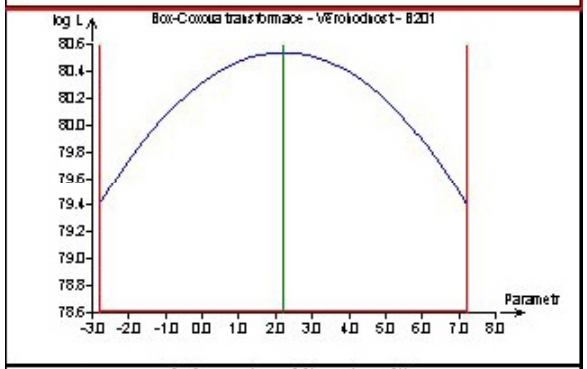

Graf logaritmu závislosti věrohodnostní funkce (osa y) na exponentu lambda. Maximu odpovídá optimální hodnota lambda. Vodorovná přímka odpovídá spodní mezi 95% intervalu spolehlivosti maxima věrohodnosti a svislé přímky odpovídají intervalu spolehlivosti odhadu lambda. Obsahuje-li tento interval 1, není nutné transformovat a je možné použít odhady v Základní statistice, případně transformaci s lambda = 1.

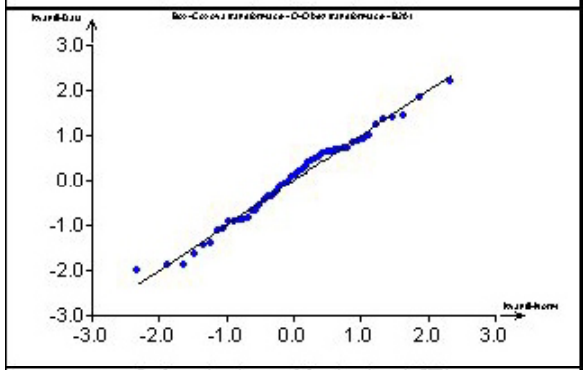

QQ-graf původních dat, shodný s QQ-grafem v Základní statistice. Metoda transformace bývá zpravidla užitečný jen pro systematicky prohnutý tvar bodů v QQ-grafu, viz vlevo. Proti statistikám má QQ-graf výhodu v možnosti vizuálně posoudit, zda je nelinearita (tedy odchylka od normality) způsobena jen několika body, nebo všemi daty.

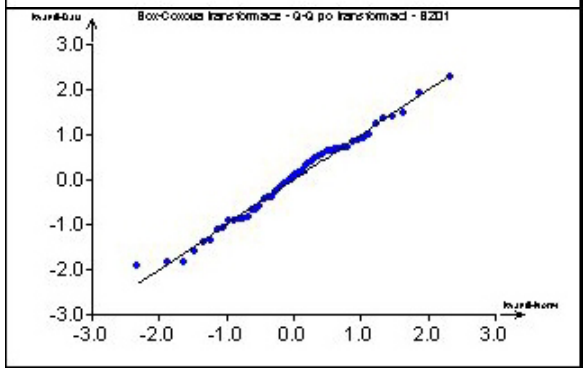

QQ-graf dat po transformaci: Je-li tvar bodů blíže přímce než na předešlém grafu, je transformace úspěšná. Ke kvantitavnímu posouzení je však třeba použít statistik uvedených v protokolu.

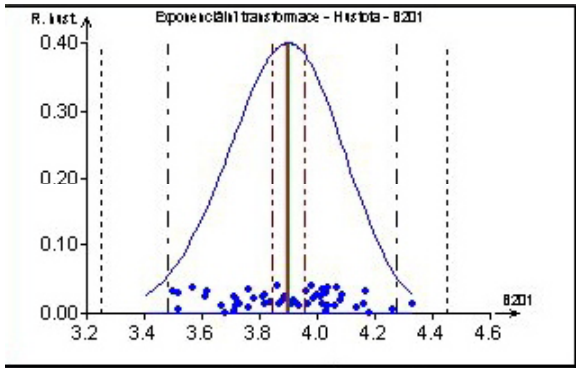

Graf hustoty představuje tvar rozdělení, který nejlépe vystihuje data prostředky Box-Coxovy transformace. Svislé čáry představují kvantily (hodnoty) odpovídající (od středu) mediánu (50% kvantil), kvartilu (25% kvantily ohraničující 50% dat), ±2s (zhruba 2.5% kvantily ohraničující interval 95% dat), 0.5% kvantily ohraničující 99% dat a ±3s (ohraničující 99.73% dat).

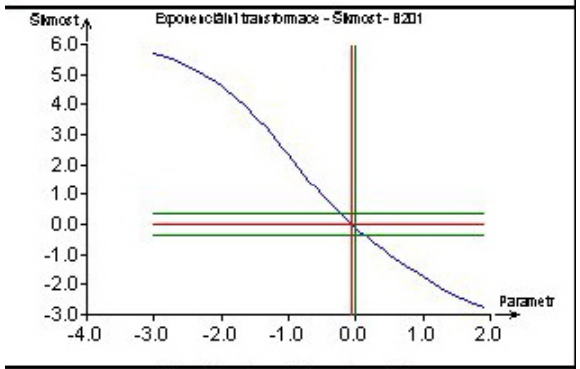

Závislost šikmosti transformovaných dat na parametru transformace: Nulová šikmost odpovídá optimálnímu parametru. Význam tohoto grafu je podobný jako u předchozího grafu věrohodnosti, slouží k nalezení parametru transformace a určení statistické významnosti transformace. Leží-li průsečík svislé zelené přímky s křivkou mimo interval spolehlivosti šikmosti (vodorovné zelené přímky), je transformace opodstatněná.

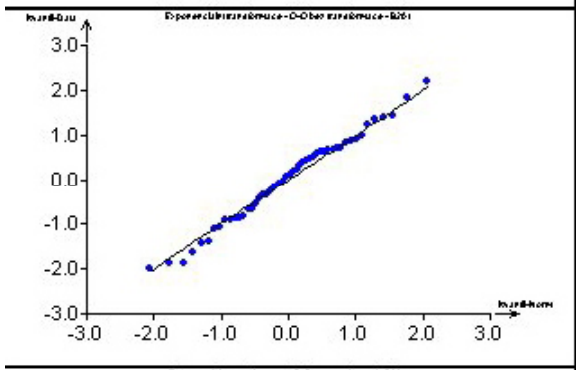

QQ-graf původních dat, shodný s QQ-grafem v Základní statistice. Metoda transformace bývá zpravidla užitečný jen pro systematicky prohnutý tvar bodů v QQ-grafu, viz vlevo. Proti statistikám má QQ-graf výhodu v možnosti vizuálně posoudit, zda je nelinearita (tedy odchylka od normality) způsobena jen několika body, nebo všemi daty.

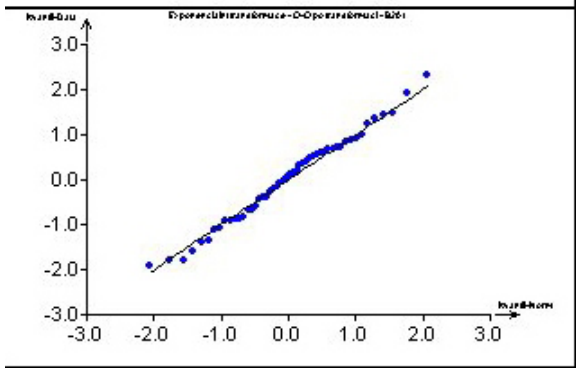

QQ-graf dat po transformaci: Je-li tvar bodů blíže přímce než na předešlém grafu, je transformace úspěšná. Ke kvantitavnímu posouzení je však třeba použít statistik uvedených v protokolu.

Box-Coxova transformace dat :

Název úlohy :	B201
Data:	Všechna
Vybrané sloupce :	
B201	

Optimální parametr :	2.220480347
Dolní mez parametru :	-2.779519653
Horní mez parametru :	7.220480291
Věrohodnost bez transformace :	80.47189562
Věrohodnost s transformací :	80.53909592
Oprávněnost transformace :	Ne
Pravděpodobnost :	28.6029656815284 %
Zvolený parametr :	2.220480347
Věrohodnost :	80.53909592
Opravený průměr :	3.898743595
LCL :	3.254893143
UCL :	4.453982689
LWL :	3.695897375
UWL :	4.091950865

Optimální parametr Nejlepší doporučená hodnota parametru r, při níž je dosaženo nejlepší shody s normálním rozdělením na základě maximální věrohodnosti.

Dolní a horní mez parametru Interval spolehlivosti optimální hodnoty r. Hodnoty uvnitř tohoto intervalu poskytnou podobný efekt jako hodnota optimální. Interval se obvykle zužuje s rostoucím počtem dat. Je-li uvnitř tohoto intervalu jednička, není účelné data transformovat buď z toho důvodu, že data již normální jsou, nebo je dat příliš málo, interval spolelivosti r je příliš široký a není možné najít jednoznačnou transformaci. Je-li uvnitř intervalu nula, lze rozdělení dat považovat za lognormální.

Věrohodnost bez transformace Hodnota logaritmu věrohodnosti normality netransformovaných dat vzhledem k normálnímu rozdělení. Protože se jedná o logaritmy, odpovídá rozdílu o 1 řádovému rozdílu.

Věrohodnost transformací Hodnota logaritmu věrohodnosti po transformaci s optimálním parametrem, tedy maximální dosažitelná shoda s normálním rozdělením. Protože se jedná o logaritmy, odpovídá rozdílu o 1 řádovému rozdílu.

Oprávněnost transformace Slovní vyjádření opodstatnění transformace. NE znamená, že transformace neposkytuje významný přínos. ANO znamená doporučení transformace. Transformace se doporučuje, je-li účinnost transformace vyšší než 95%.

Účinnost transformace Statistická významnost transformace. Je v podstatě kvantitativním vyjádřením oprávněnosti transformace (předchozí položka). Je-li účinnost větší než 95%, považuje se transformace za oprávněnou a doporučenou, jinak se transformace nedoporučuje. Hranice 95% však není striktní. Je-li účinnost blízká 95%, lze rozhodnout i opačně.

Zvolený parametr Hodnota uživatelem zadaného parametru v dialogovém panelu. Tato hodnota může být různá od doporučené optimální hodnoty.

Věrohodnost Logaritmus věrohodnosti odpovídající zvolenému parametru.

Opravený průměr Aritmetický průměr vypočítaný metodou Box-Coxovy transformace. V případě asymetrických dat odpovídá střední hodnotě lépe než prostý průměr počítaný v Základní statistice.

LCL Doporučená hodnota spodní kontrolní meze pro případ konstrukce Shewhartova regulačního diagramu typu X-průměr. Počet sloupců je chápán jako velikost podskupiny.

UCL Doporučená hodnota spodní kontrolní meze pro případ konstrukce Shewhartova regulačního diagramu typu X-průměr. Počet sloupců je chápán jako velikost podskupiny.

LWL Doporučená hodnota spodní varovné meze.

UWL Doporučená hodnota horní varovné meze.

Exponenciální transformace dat :

Název úlohy :	B201
Data:	Všechna
Vybrané sloupce :	
B201	
Optimální parametr :	-0.05795288086
Zvolený parametr :	-0.05795288086
Oprávněnost transformace :	Ne
Opravený průměr :	3.899547054
Interval spolehlivosti :	
Spodní :	3.842812816
Horní :	3.95535866
LCL :	3.250862643
UCL :	4.447294615
LWL :	3.479724116
UWL :	4.274265575

Optimální parametr Nejlepší doporučená hodnota parametru r, při níž je dosaženo nejlepší shody s normálním rozdělením na základě maximální věrohodnosti.

Dolní a horní mez parametru Interval spolehlivosti optimální hodnoty r. Hodnoty uvnitř tohoto intervalu poskytnou podobný efekt jako hodnota optimální. Interval se obvykle zužuje s rostoucím počtem dat. Je-li uvnitř tohoto intervalu jednička, není účelné data transformovat buď z toho důvodu, že data již normální jsou, nebo je dat příliš málo, interval spolelivosti r je příliš široký a není možné najít jednoznačnou transformaci. Je-li uvnitř intervalu nula, lze rozdělení dat považovat za lognormální.

Věrohodnost bez transformace Hodnota logaritmu věrohodnosti normality netransformovaných dat vzhledem k normálnímu rozdělení. Protože se jedná o logaritmy, odpovídá rozdílu o 1 řádovému rozdílu.

Věrohodnost transformací Hodnota logaritmu věrohodnosti po transformaci s optimálním parametrem, tedy maximální dosažitelná shoda s normálním rozdělením. Protože se jedná o logaritmy, odpovídá rozdílu o 1 řádovému rozdílu.

Oprávněnost transformace Slovní vyjádření opodstatnění transformace. NE znamená, že transformace neposkytuje významný přínos. ANO znamená doporučení transformace. Transformace se doporučuje, je-li účinnost transformace vyšší než 95%.

Účinnost transformace Statistická významnost transformace. Je v podstatě kvantitativním vyjádřením oprávněnosti transformace (předchozí položka). Je-li účinnost větší než 95%, považuje se transformace za oprávněnou a doporučenou, jinak se transformace nedoporučuje. Hranice 95% však není striktní. Je-li účinnost blízká 95%, lze rozhodnout i opačně.

Zvolený parametr Hodnota uživatelem zadaného parametru v dialogovém panelu. Tato hodnota může být různá od doporučené optimální hodnoty.

Věrohodnost Logaritmus věrohodnosti odpovídající zvolenému parametru.

Opravený průměr Aritmetický průměr vypočítaný metodou Box-Coxovy transformace. V případě asymetrických dat odpovídá střední hodnotě lépe než prostý průměr počítaný v Základní statistice.

LCL Doporučená hodnota spodní kontrolní meze pro případ konstrukce Shewhartova regulačního diagramu typu X-průměr. Počet sloupců je chápán jako velikost podskupiny.

UCL Doporučená hodnota spodní kontrolní meze pro případ konstrukce Shewhartova regulačního diagramu typu X-průměr. Počet sloupců je chápán jako velikost podskupiny.

LWL Doporučená hodnota spodní varovné meze.

UWL Doporučená hodnota horní varovné meze.

4. Parametry polohy, rozptýlení a tvaru:

Analýza 1 výběru: *klasické odhady* - *průměr*

- *rozptyl*

robustní odhady - *medián*

- *uřezané průměry*
- *winsorizovaný rozptyl*
- *interkvantilové rozpětí*

adaptivní odhady

```
V Ý S L E D K Y

                    ZÁKLADNÍ STATISTIKA

              Analýza jednorozměrného výběru

Název : B201

                          V S T U P

(1) DATA A PODMÍNKY:
    Počet dat                    : 50
    Hladina významnosti alfa     : 0.050
    Název výstupního souboru     : RESULTS.TXT

(2) VSTUPNÍ DATA:

 (  1)  3.8600E+00 ( 14) 4.0400E+00 ( 27) 4.0200E+00 ( 40) 4.0200E+00
 (  2)  4.0600E+00 ( 15) 3.9300E+00 ( 28) 3.8200E+00 ( 41) 4.0800E+00
 (  3)  3.6700E+00 ( 16) 4.1400E+00 ( 29) 3.6200E+00 ( 42) 4.0400E+00
 (  4)  3.9700E+00 ( 17) 3.8800E+00 ( 30) 3.6800E+00 ( 43) 3.7800E+00
 (  5)  3.7600E+00 ( 18) 3.8400E+00 ( 31) 4.1700E+00 ( 44) 3.9800E+00
Napověda-F1   Řádek: 1 - 23                Celkem: 112   Délka: 3926
```

V Ý S L E D K Y

```
(1) PARAMETRY TVARU:

                    Šikmost      : -1.1912E-01
                    Špičatost    :  2.4016E+00

(2) KLASICKÉ ODHADY PARAMETRŮ :
    Průměr                 :   3.8940E+00
    Směr. odchylka         :   1.9849E-01
    Rozptyl                :   3.9400E-02
    95.0% spolehlivost:
    Spodní mez:  3.8376E+00   Horní mez:  3.9504E+00

(3) OSTATNÍ ODHADY POLOHY:


    Odhad modu             :   4.0300E+00
    Odhad polosumy         :   3.9150E+00

(4) ROBUSTNÍ ODHADY PARAMETRŮ :
    Medián                 :   3.9150E+00
    Směr. odchylka mediánu:    2.6014E-01
    Rozptyl mediánu        :   6.7675E-02
    Rozptyl (nepar.)       :   2.0250E-03
```

Napověda-F1 Řádek: 35 - 57 Celkem: 112 Délka: 3926

V Ý S L E D K Y

```
    Uřezání 10% (pro P=0.10):
    Průměr                 :   3.8970E+00
    Směr. odchylka         :   2.1447E-01
    Rozptyl                :   4.5998E-02
    Průměr, winsor.        :   3.8936E+00
    St.odch. winsor.       :   1.8942E-01
    Rozptyl, winsor.       :   3.5879E-02
    95.0% spolehlivost:
    Spodní mez:  3.8357E+00  Horní mez:   3.9583E+00

    Uřezání 40% (pro P=0.40):
    Průměr                 :   3.9130E+00
    Směr. odchylka         :   2.7268E-01
    Rozptyl                :   7.4357E-02
    Průměr, winsor.        :   3.9146E+00
    St.odch. winsor.       :   1.1569E-01
    Rozptyl, winsor.       :   1.3384E-02
    95.0% spolehlivost:
    Spodní mez:  3.8271E+00  Horní mez:   3.9989E+00

    Biweight:
    Průměr                 :   3.8966E+00
    Směr. odchylka         :   1.9826E-01
```

Napověda-F1 Řádek: 75 - 97 Celkem: 112 Délka: 3926

V Ý S L E D K Y

```
(4) ROBUSTNÍ ODHADY PARAMETRŮ :
    Medián                 :   3.9150E+00
    Směr. odchylka mediánu:    2.6014E-01
    Rozptyl mediánu        :   6.7675E-02
    Rozptyl (nepar.)       :   2.0250E-03
    Směr. odchylka mediánu:    4.5000E-02
    Rozptyl (Marritz)      :   1.9250E-03
    Směr. odchylka mediánu:    4.3875E-02
    95.0% spolehlivost:
    Spodní mez:  3.8268E+00  Horní mez:  4.0082E+00


    Uřezání 5% (pro P=0.05):
    Průměr                 :   3.8942E+00
    Směr. odchylka         :   2.0668E-01
    Rozptyl                :   4.2717E-02
    Průměr, winsor.        :   3.8898E+00
    St.odch. winsor.       :   1.9526E-01
    Rozptyl, winsor.       :   3.8128E-02
    95.0% spolehlivost:
    Spodní mez:  3.8356E+00  Horní mez:   3.9528E+00

    Uřezání 10% (pro P=0.10):
```

Napověda-F1 Řádek: 53 - 75 Celkem: 112 Délka: 39

V Ý S L E D K Y

```
    Biweight:
    Průměr                 :   3.8966E+00
    Směr. odchylka         :   1.9826E-01
    Rozptyl                :   3.9306E-02
    Váhy sqrt(w)           :   6.7659E+00
    95.0% spolehlivost:
    Spodní mez:  3.8377E+00   Horní mez:  3.9555E+00

(5) ADAPTIVNÍ ODHADY PARAMETRŮ:

    Hoggovy  odhady:
    Relativní délka konců :    2.3753E+00
    Průměr                 :   3.8940E+00
    Směr. odchylka         :   1.9849E-01
    Rozptyl                :   3.9400E-02
    95.0% spolehlivost:
    Spodní mez:  3.8376E+00   Horní mez:  3.9504E+00
```

Napověda-F1 Řádek: 94 - 112 Celkem: 112 Délka: 3926

Úlohy k EDA:

B202
B203
B204
B206
B207
B208
B209
B210
B212
B217
B218
B219
B220
B221
B224