

**Katedra štatistiky,
Fakulta hospodárskej informatiky,
Ekonomická univerzita v Bratislave**



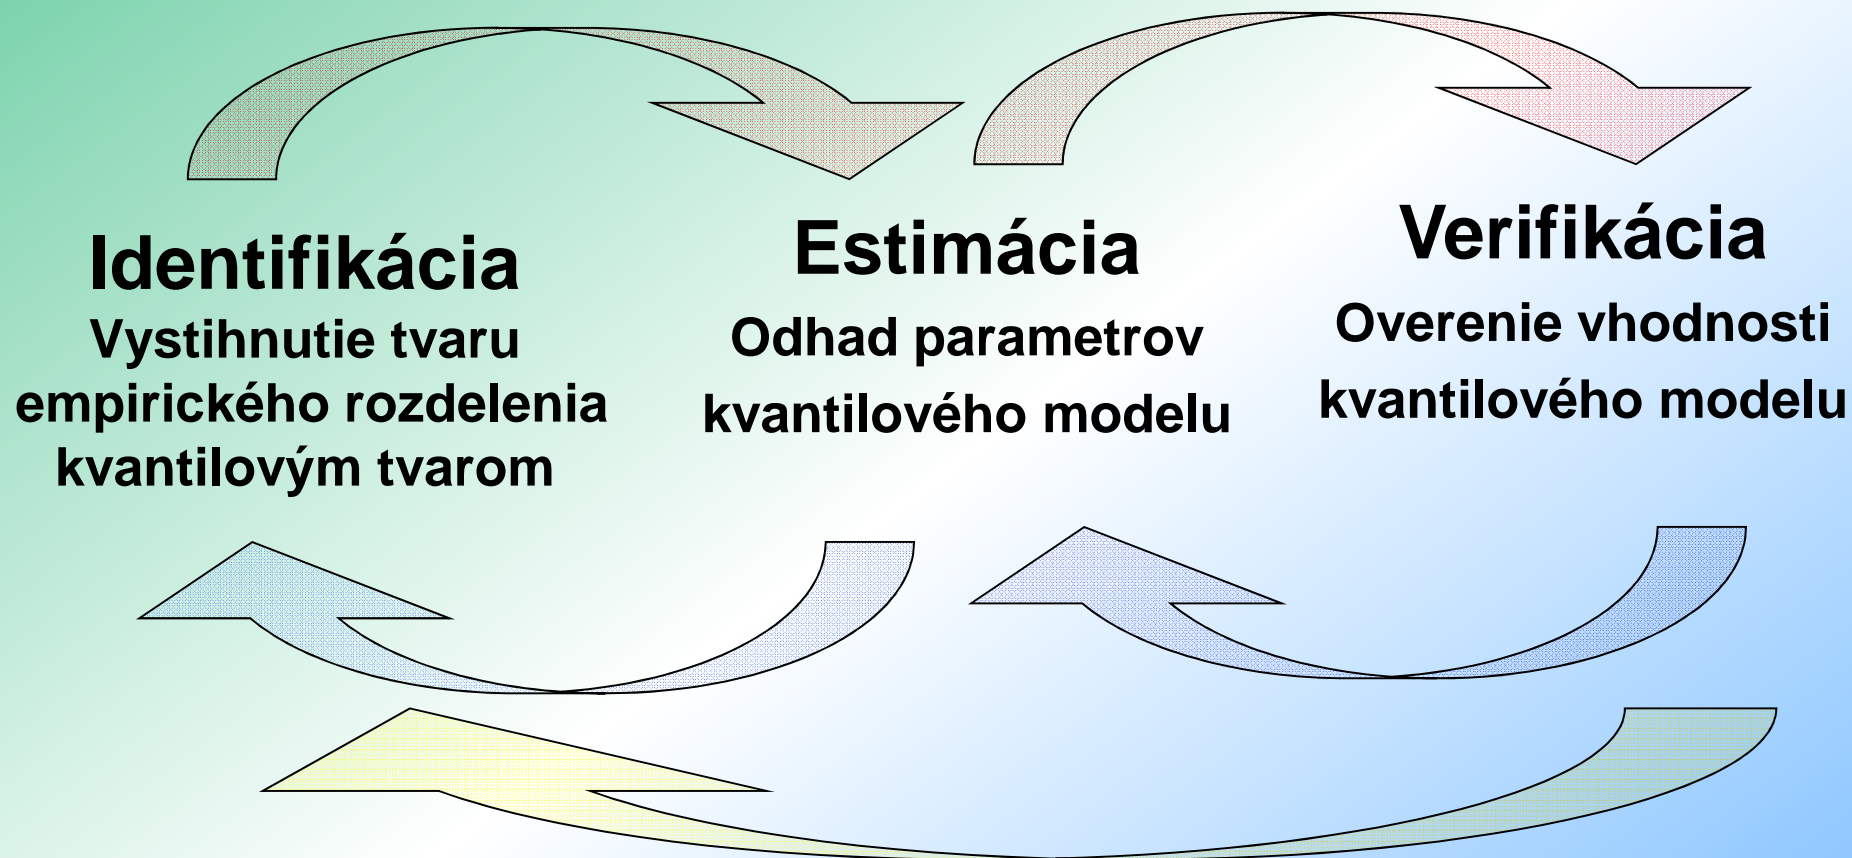
**Pravdepodobnostné modelovanie
inverznými distribučnými funkciami :
Identifikácia kvantilového modelu**

Ľubica SIPKOVÁ

Apríl 2009

3. z cyklu prezentácií

Fázy kvantilového modelovania



Proces interaktívny, revidujúci predchádzajúce výsledky novými zisteniami s vrátením sa s novými informáciami k predchádzajúcim fázam, postupom a technikám.


Identifikácia

Vystihnutie tvaru empirického rozdelenia

- Grafická identifikácia empirického rozdelenia
- Kvantitatívna analýza empirického rozdelenia:
 - na momentovom základe
 - na kvantilovom základe
- Identifikácia rozdelenia jednoduchými tvarmi
 - Celého rozdelenia
 - Zvlášť pre dolný a horný koniec
- Voľba tvaru váh pre konce rozdelenia
 - Ako funkcia p
 - Ako parametre modelu

Grafická analýza celého aj častí empirického rozdelenia $(Q_{emp}(p)=CP)$


Hodnota príjmov v závislosti od ich proporcionálneho postavenia vo vzostupnom usporiadaní



Grafická analýza empirického rozdelenia

Príjmy domácností SR v roku 2003

$$(Q_{emp}(p) = CP)$$




Grafická analýza empirického rozdelenia

Príjmy domácností SR v roku 2003

$$(Q_{\text{emp}}(p) = CP)$$

CP v závislosti od p (pre CP v kvartilovom rozpätí)


Empirická kvantilová funkcia pre hodnoty medzi kvartilmi



Grafická analýza empirického rozdelenia

Príjmy domácností SR v roku 2003


$$(Q_{emp}(p) = CP)$$



Grafická analýza celého aj častí empirického rozdelenia

(Box-Plot)

Box-and-Whisker graf pre CP




Grafická analýza empirického rozdelenia

Príjmy domácností SR v 2003

(Box-Plot)

Box-and-Whisker Plot pre dolných 95% hodnôt CP



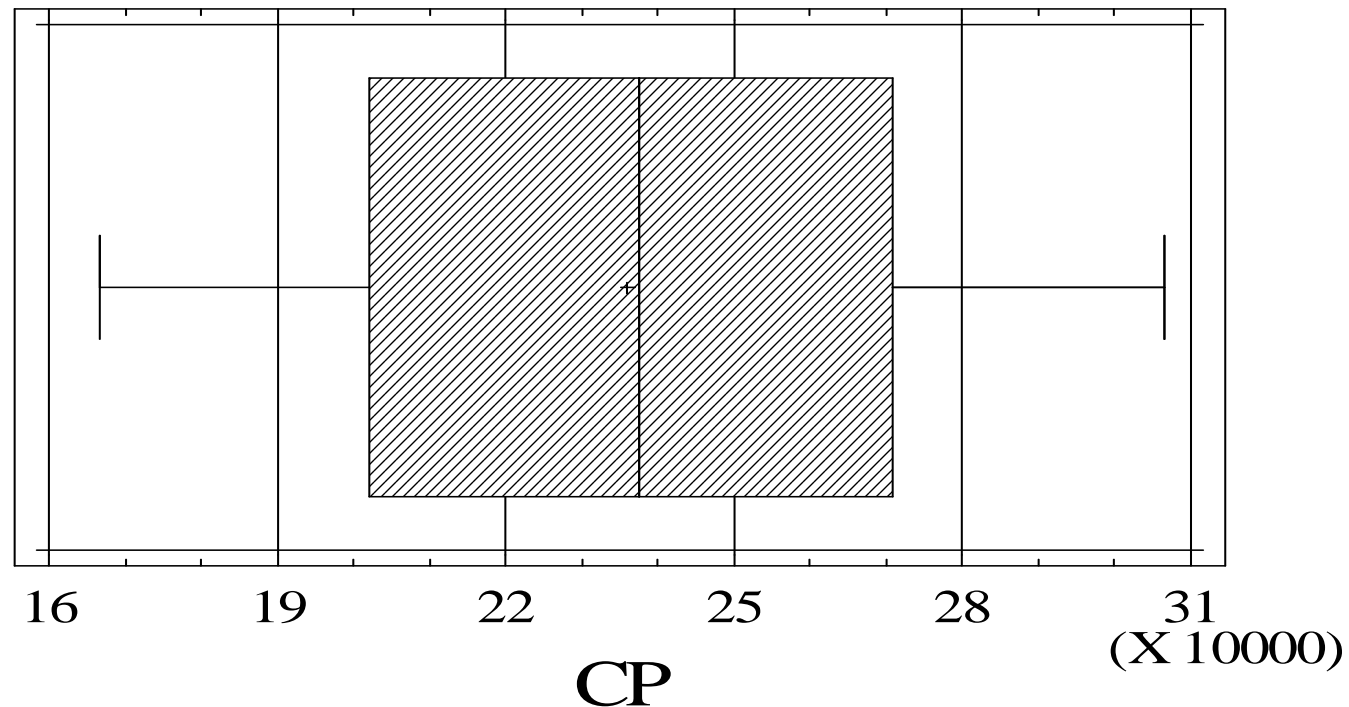
Takmer symetrické rozdelenie bez horných 5% hodnôt

Grafická analýza empirického rozdelenia

Príjmy domácností SR v 2003

(Box-Plot)

Box-and-Whisker Plot pre prostrednú polovicu hodnôt CP




Symetrická prostredná časť medzi kvartilmi

Grafická analýza empirického rozdelenia

Príjmy domácností SR v 2003

Polygón

Polygón rozdelenia početností pre CP

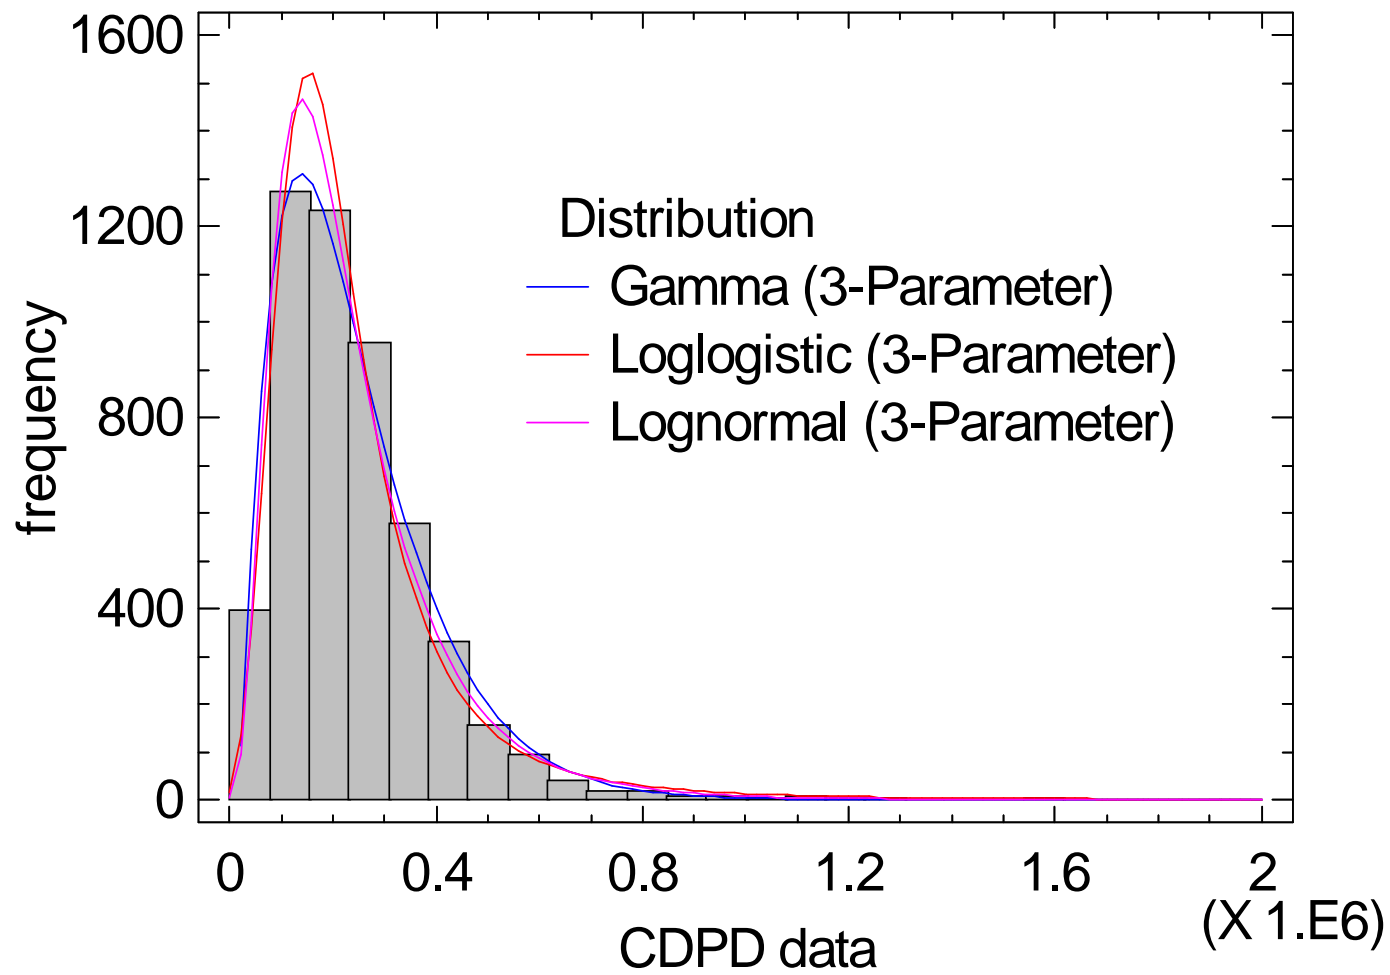


Porovnanie zhody so známymi jednoduchými tvarmi pomocou procedúry:

Comparison of Alternative Distributions

<i>Distribution</i>	<i>Est. Parameters</i>	<i>Log Likelihood</i>	<i>KS D</i>
Lognormal (3-Parameter)	3	-67677.7	0.0362935
Lognormal	2	-67704.9	0.0397763
Loglogistic	2	-67730.3	0.0496562
Gamma (3-Parameter)	3	-67743.3	0.0244112
Birnbaum-Saunders	2	-67763.8	0.0479773
Gamma	2	-67775.9	0.0292224
Inverse Gaussian	2	-67789.4	0.0550491
Largest Extreme Value	2	-67873.8	0.0483855
Weibull	2	-68026.0	0.0646936
Logistic	2	-68477.7	0.0910885
Laplace	2	-68514.9	0.108414
Exponential	1	-68795.9	0.199527
Normal	2	-69321.9	0.120725

Histogram for CDPD data



KS a CHI kv. Testy pre CDPD

KS Test	Erlang	Gamma (3-Parameter)	Loglogistic (3-Parameter)	Weibull (3-Parameter)	Lognormal (3-Parameter)
DPLUS	0.0	0.0244112	0.0494693	0.0399911	0.0362935
DMINUS	1.0	0.0227598	0.0365427	0.0527996	0.0303411
DN	1.0	0.0244112	0.0494693	0.0527996	0.0362935
P-Value	0.0	0.00437615	0.0	0.0	0.00000264

Chi kv. Test	Gamma	Gamma (3-Parameter)	Lognormal	Lognormal (3-Parameter)
Chi-Squared	399.179	379.992	394.717	354.507
D.f.	97	96	97	96
P-Value	0.0	0.0	0.0	0.0

Kvantitatívna analýza empirického rozdelenia

Príjmy domácností SR v 2003

Výberové charakteristiky

➤ na momentovom základe

Priemer	= 244 284 Sk	Koeficient šikmosti	= +1.0498
Rozptyl	= 1.2012E10	Štand. šikmost'	= 16.959
Štandardná odchýlka	= 109 598 Sk	Pearsonova špicatost'	= 2.997
Variačný koeficient	= 44.87 %	Štand. špicatost'	= 24.209

➤ na kvantilovom základe

Medián		= 237 407 Sk
Kvartilové rozpätie		= 139 770 Sk
Galtonov koeficient šikmosti	$g=qd/iqr$	= -0.0123
Kvartilová diferencia	$qd=lq+uq-2$	= -1718.50
Moorsova špicatost'	$k=[(e7-e5)+(e3-e1)]/iqr$	= 1.174

Čo by sme už mali vedieť na základe doterajšej identifikácie ?

- **nevhodnosť modelovať klasickým prístupom**
(nedostatočná „dobrá zhoda“ jednoduchých rozdelení)
- **obor funkčných hodnôt** (hranice, limity rozdelenia)
- **symetria – asymetria** (smer a intenzita asymetrie empirického rozd. a jeho častí)
- **výsledky z histórie skúmania** (známe modely aplikované v minulosti u podobnej *NP* – overenie týchto tvarov pomocou Q-Q grafov)

Zopakujme všeobecné požiadavky na model

– kvalita a preferencie medzi modelmi sa budú posudzovať podľa ich splnenia

- vhodný na nadväzujúce analýzy, na vyjadrenie základných súhrnných charakteristík, má splniť svoj praktický účel
- „dobrá zhoda“ – štatisticky významný
- jednoduchosť (jednomodálnosť)
- možnosť aktualizácie v čase
- aplikovateľnosť viacnásobného prístupu – modelovanie v podsúboroch, v štruktúrach
- možnosť aplikácie simulačných metód

Dva prístupy ku kvantilovému modelovaniu

1. Aplikovať „odskúšané“ komplexné elastické tvary
 - **použiť známe zovšeobecnené tvary**
2. Kombinovať jednoduché kvantilové tvary pomocou matematického aparátu a dať im príslušnú váhu v častiach rozdelenia
 - **skladaním kvantilového tvaru „na mieru“**

1. Zovšeobecnené tvary

- definované **kvantilovou funkciou** (inverznou distribučnou funkciou)
- veľmi **elastické** (flexibilné) ľahko menia tvar, obor funkčných hodnôt (max, min), limity, inflexné body, rozloženie, asymetriu...
- sú **viacparametrické**, často s parametrom polohy, rozloženia, parametrami pre horný a dolný koniec

Zovšeobecnený tvar RS GLD

Tvar štvor-parametrického asymetrického
zovšeobecného lambda rozdelenia podľa
Ramberga a Schmeisera :

$$F^{-1}(p) = \lambda_1 + \frac{p^{\lambda_3} - (1-p)^{\lambda_4}}{\lambda_2} ; 0 \leq p \leq 1$$

používa dva lineárne a dva nelineárne parametre

Základný tvar má dva parametre pre dolný a horný koniec, ktoré spoločne modelujú šikmosť a špicatosť

je extrémne elastický

2. Skladanie kvantilových tvarov

- **rozdelenia v základnom tvare** známeho jednoduchého kvantilového rozdelenia
 - bez parametrov polohy a stupnice (variability, rozloženia)
- potrebné **identifikovať tvar zvlášť dolného a zvlášť horného konca** pomocou empirického rozdelenia
- možno modifikovať kvantilové funkcie pomocou matematických operácií (**základné pravidlá modifikácie kvantilových funkcií**)
- zvoliť **vhodné váhy** týmito dvoma tvarom

$$X \sim Q[p; \Theta]$$

Definovanie kvantilového modelu

$$Q(p) = F^{-1}(p) = x, \quad 0 \leq p \leq 1$$

Jednoduchý kvantilový model v tvare :

$$Q(p) = \lambda + \eta S(p) \quad 0 \leq p \leq 1$$

môže byť lineárnym, alebo semilineárnym
dvoj a viacparametrickým
kvantilovým distribučným modelom

v závislosti od jeho **základného kvantilového tvaru** :

$$S(p)$$

Základné kvantilové tvary známych pravdepodobnostných rozdelení

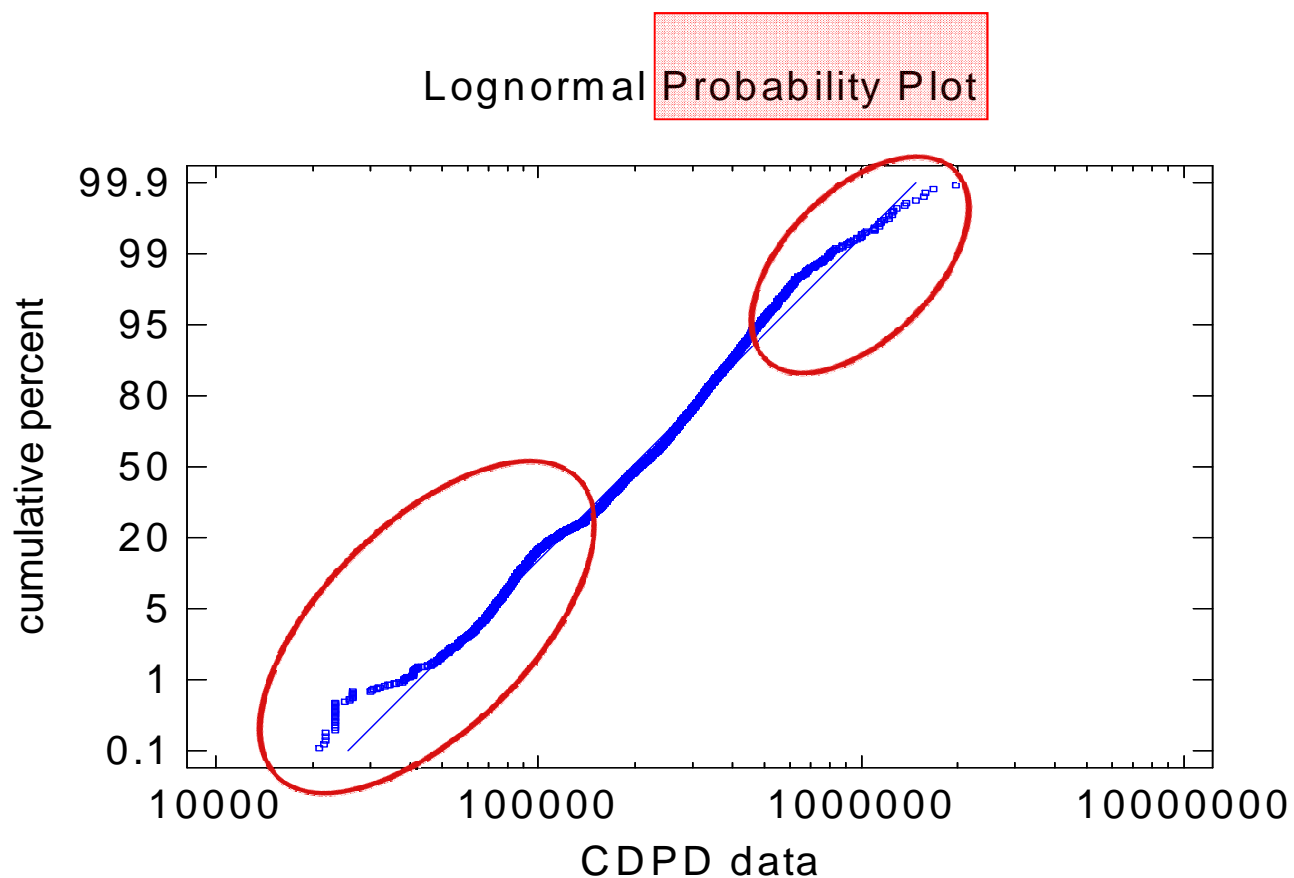
Distribution	F(x)	S(p)	Dist. range
<i>Exponential</i>	$1 - e^{-x}$	$-\ln(1-p)$	$(0, \infty)$
<i>Uniform</i>	x	p	$(0, 1)$
<i>Power</i>	$\frac{1}{x^\alpha}$	p^α	$(0, 1), \beta > 0$
<i>Pareto</i>	$1 - \frac{1}{(1+x)^\beta}$	$\frac{1}{(1-p)^\beta}$	$(0, \infty), \beta > 0$
<i>Weibull</i>	$1 - e^{-x^{\frac{1}{\beta}}}$	$[-\ln(1-p)]^\beta$	$(0, \infty), \beta > 0$
<i>Extreme value</i>	$e^{-e^{-x}}$	$-\ln(-\ln p)$	$(-\infty, +\infty)$
<i>Logistic</i>	$\frac{1}{1+e^{-x}}$	$\ln \frac{p}{1-p}$	

Vystihnutie tvaru empirického rozdelenia - identifikácia

- Grafická analýza empirického rozdelenia príjmov
- Kvantitatívna analýza empirického rozdelenia príjmov:
 - na momentovom základe
 - na kvantilovom základe
- Identifikácia rozdelenia jednoduchými tvarmi
 - Celého rozdelenia
 - Zvlášť pre dolný a horný koniec
- Voľba tvaru váh pre konce rozdelenia
 - Ako funkcia p
 - Ako parametre modelu

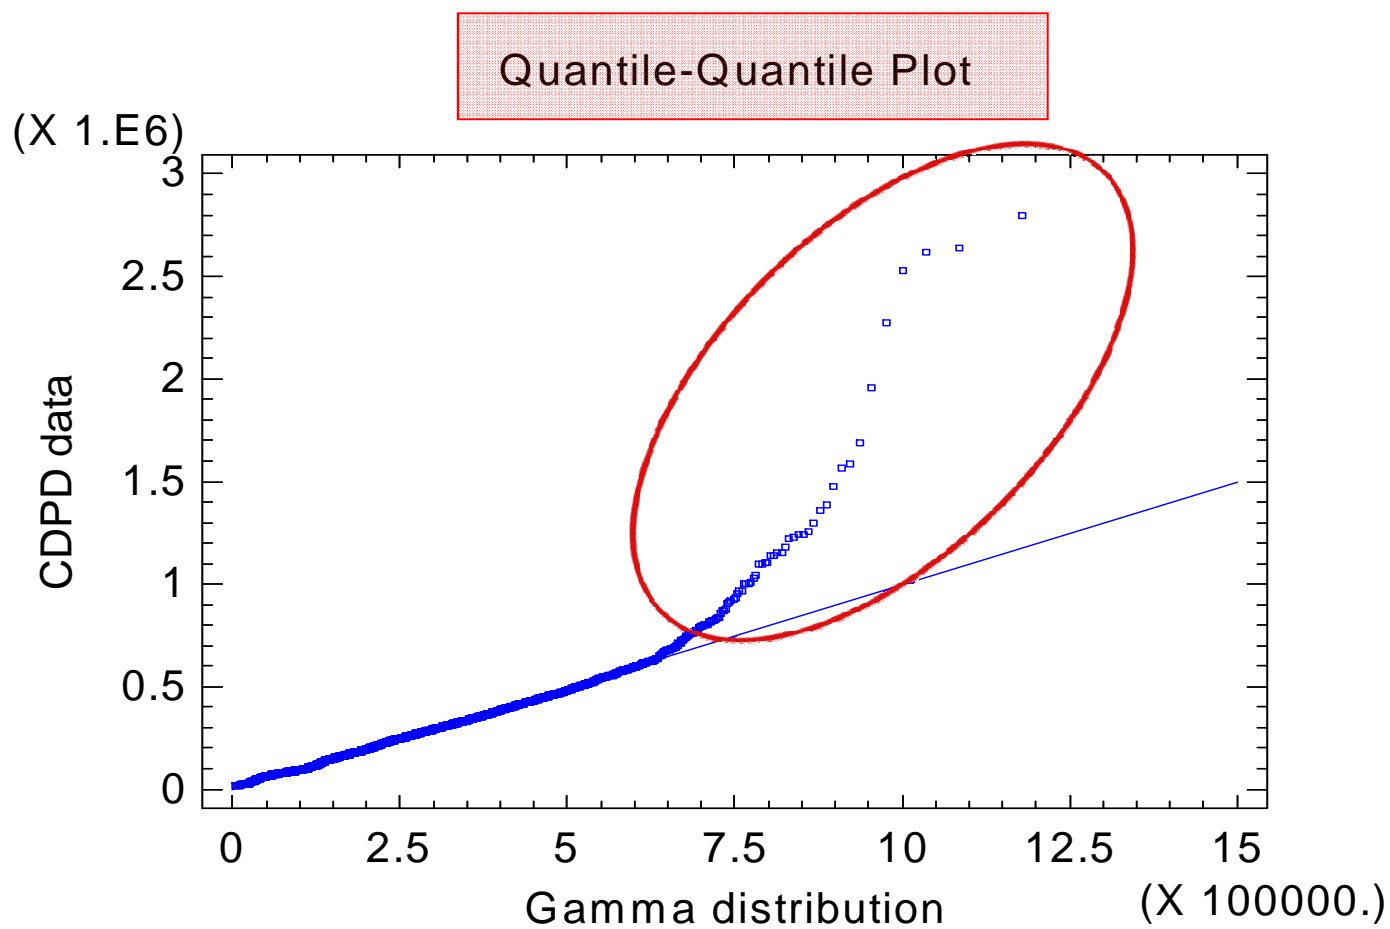
Identifikácia rozdelenia pomocou pravdepodobnostných grafov

napr. v STATGRAPHICS CENTURION XV pre Lognormálne 3-parametrické rozdelenie



Identifikácia rozdelenia Q-Q grafmi

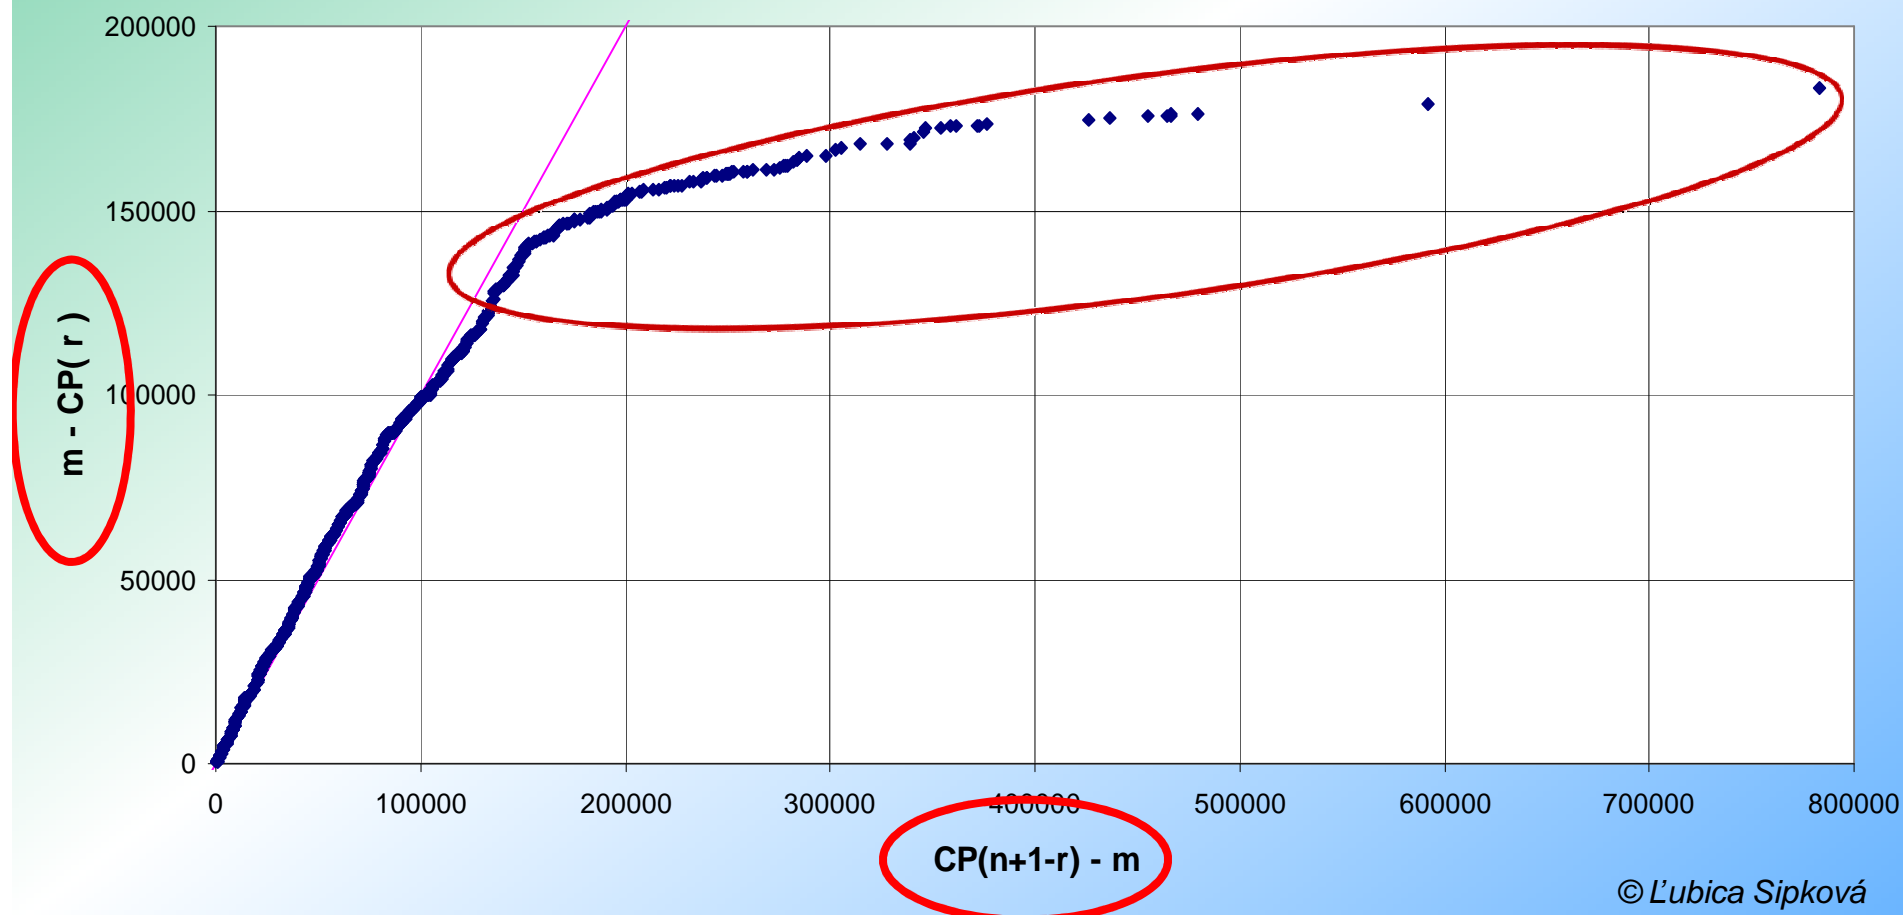
napr. pomocou STATGRAPHICS CENTURION XV
pre Gamma 3-parametrické rozdelenie



Identifikácia rozdelenia Q-Q grafmi porovnania vzdialenosti horných a dolných kvantilov od mediánu

(v Exceli, ale možno aj pomocou STATGRAPHICS CENTURION XV)


Porovnanie odchýlok hodnôt CP od mediánu (pravého konca oproti ľavému koncu rozdelenia CP)



Identifikácia **len koncov** rozdelenia jednoduchými tvarmi

Useknutý Weibullov tvar pre dolný koniec


Histogram pre CP s funkciou hustoty Weibullovho rozdelenia



Identifikácia rozdelenia jednoduchými tvarmi


Aké rozdelenie použiť pre horný koniec?

Identifikačný graf pre Exponenciálne rozdelenie




Identifikácia rozdelenia jednoduchými tvarmi

Identifikačný graf pre Weibullovo rozdelenie




Identifikácia rozdelenia jednoduchými tvarmi

Identifikačný graf pre logistické rozdelenie



Identifikácia rozdelenia jednoduchými tvarmi

Identifikačný graf pre Burr III rozdelenie



Identifikácia rozdelenia jednoduchými tvarmi

Identifikačný graf pre Paretovo rozdelenie



V identifikačných grafoch nesledujeme sklon preloženej priamky

Prečo sa v nich zameriame len na šikmost' a špicatosť rozdelení?

- možnosť ľahko zmeniť polohu a variabilitu kvantilových funkcií:
 - posunutím
 - centrovaním
 - normovaním
- $$Q(p) = \lambda + \eta S(p)$$
- $S(p)$ má vlastné parametre šikmosti, špicatosti, alebo parametre koncov rozdelenia, ktoré spolu definujú jeho šikmost' a špicatosť

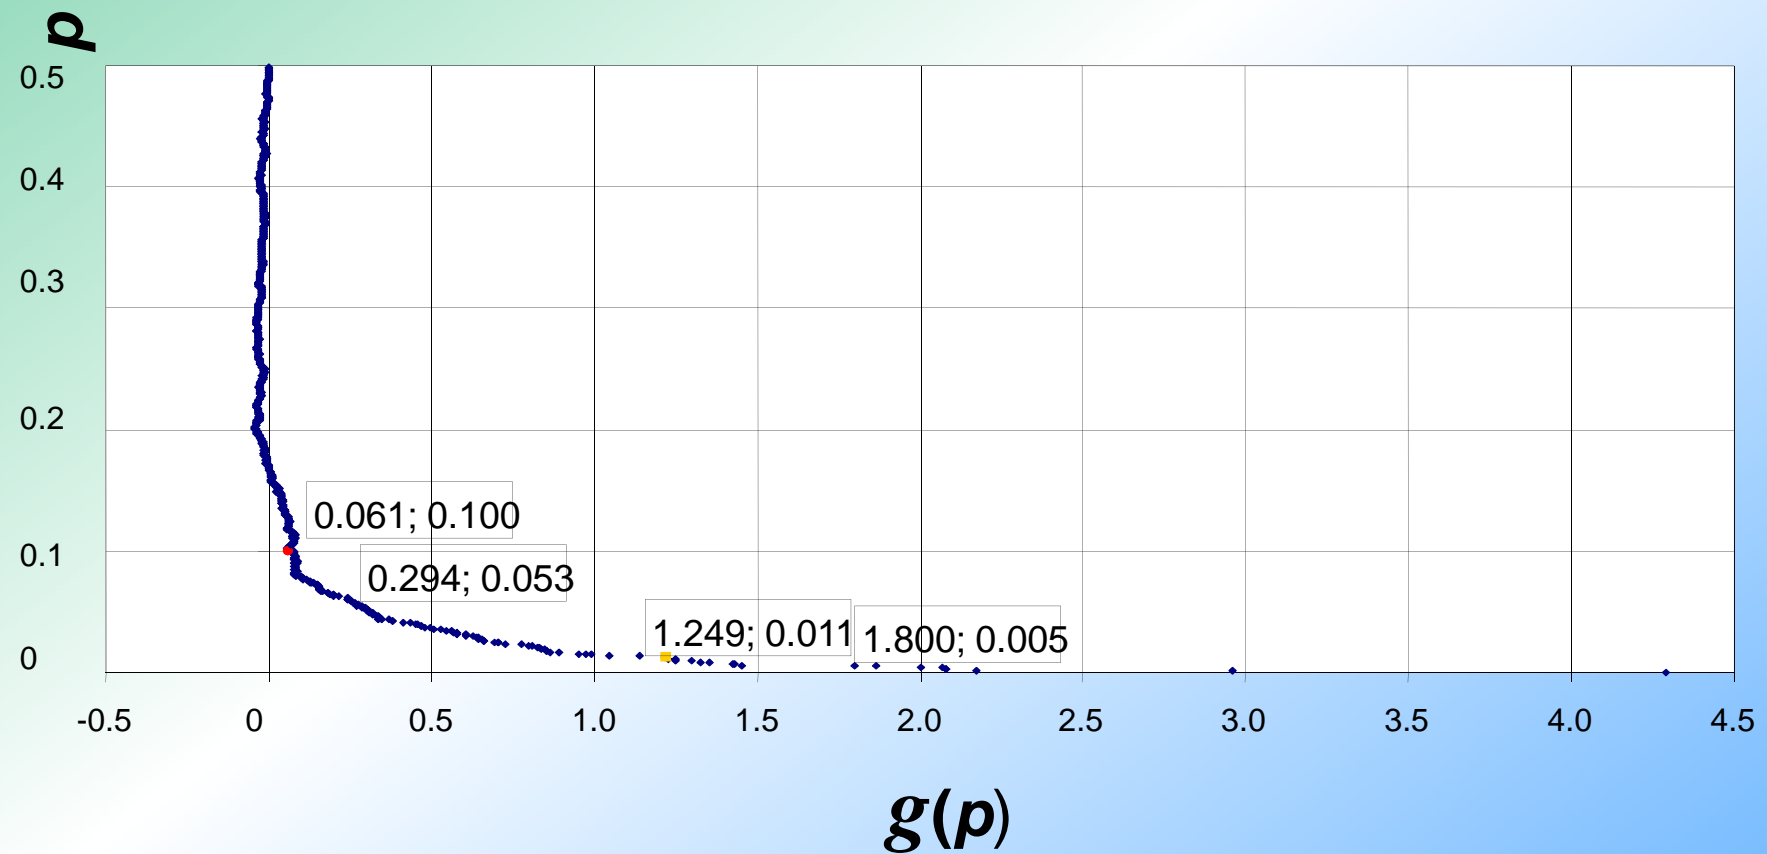
Identifikačné grafy

pre znázornenie šikmosti a špicatosti v empirickom súbore


- Galtonova šikmost' $g(p)$ oproti p_r
 - Galtonova p -šikmost' $g^*(p)$ oproti p_r
 - indexu špicatosti $t(p)$ oproti p_r
 - horného indexu špicatosti $ut(p)$ oproti p_r
 - dolného indexu špicatosti $lt(p)$ oproti p_r
- a ich porovnaním s tvarmi pre simulované hodnoty teoretických rozdelení

Graf Galtonovej šikmosti pre empirické dáta

Galtonova šikmost' empirického rozdelenia CP



Graf Galtonovej šikmosti pre teoretické rozdelenie



Tvar váh pre dva konce rozdelenia – možné voliť ako funkciu pravdepodobnosti pre plynulý prechod z jedného tvaru do druhého

Ako funkcia p

$$(1-p) \quad \text{a} \quad p$$

$$\left[1 - p^2(3-2p)\right] \quad \text{a} \quad p^2(3-2p)$$

$$\left[1 - p^3(10-15p+6p^2)\right] \quad \text{a} \quad p^3(10-15p+6p^2)$$

$$1 - \omega(p) \quad \text{a} \quad \omega(p)$$

Ako parametre modelu

$$(1-\omega) \quad \text{a} \quad \omega$$

$$\frac{(1+\omega)}{2} \quad \text{a} \quad \frac{(1-\omega)}{2}$$

$$\omega_1(1-p) \quad \text{a} \quad \omega_2 p$$

Ako môže vyzerat' **poskladaný (zložený)** kvantilový model?

$$Q_{CP}(p) = \lambda + \eta \left\{ (1-p)[- \ln(1-p)]^\beta + p \left[\frac{1}{(1-p)^\gamma} \right] \right\}$$

$, 0 < p < 1, \beta > 0, \gamma > 0$

Weibullovo-Pareto tvar:

- parameter polohy
- parameter stupnice, variability
- kvantilový základný tvar rozdelenia pre dolný koniec s jeho parametrami
- kvantilový základný tvar rozdelenia pre horný koniec s jeho parametrami
- váhy jednotlivým rozdeleniam

**Pravdepodobnostné modelovanie
inverznými distribučnými funkciami:
Identifikácia kvantilového modelu**

Spracovanie **tretej** z cyklu prezentácií o kvantilovom modelovaní.

Podrobnejšie možno nájsť v monografii:

Sipková, Ľ; Sodomová, E.: Modelovanie kvantilovými funkciami, Vydavateľstvo EKONÓM, Bratislava, 2007; 175 s.

ISBN 978-80-225-2346-2

Ľubica SIPKOVÁ
apríl 2009