

USEKNUTÉ ODHADY V MODELU NELINEÁRNÍ REGRESE

B. Procházka

MŠP SKÚ, Žižkovo náměstí 48 Praha 10

Zpráva o výsledcích kandidátské práce

Školitel: doc. RNDr. J. Jurečková, DrSc. MFF UK Praha

Jedním z prvních problémů, kterým se zabývala matematická statistika od počátku své existence, je regresní model. Při řešení praktických problémů se však často setkáváme s nutností zabývat se nejen modely lineárního vztahu sledovaných veličin, ale často i se složitějšími modely. Práce se zabývá nelineárním regresním modelem, ve tvaru $y = g(x, \theta) + \epsilon$, kde y je závisle proměnná, x je nezávisle proměnná, θ neznámý parametr, ϵ náhodná chyba a $g(\cdot)$ regresní funkce známého analytického tvaru, nelineární v parametru θ . V principu mohou nastat dva případy :

1/ existuje transformace regresní funkce na lineární tvar (jako příklad můžeme uvést model s regresní funkci $e^{\theta_0 x}$). V praxi se tento model řeší často právě touto transformací. Dále bývají většinou používány metody odhadu v lineárním regresním modelu. Je však nutné si uvědomit, že touto transformací se dopouštíme závažného zkreslení chyby ϵ a jejího rozložení, je tedy nutno odhadovat parametry v původním regresním modelu.

2/ Neexistuje transformace regresní funkce na lineární tvar (jako příklad můžeme uvést model s regresní funkci $e^{\theta(1)x} - e^{\theta(2)x}$). Pak máme situaci v rozhodování o volbě metody jednodušší - je nutno v každém případě použít některou z metod nelineární regrese.

Běžnými požadavky, kladenými na regresní model, přesněji řečeno na náhodnou chybu ϵ jsou předpoklady :

1/ Chyby $\epsilon_1, \dots, \epsilon_n$ jsou nezávislé, stejně rozdelené.

2/ Rozdelení ϵ_i je symetrické okolo 0.

3/ Rozdelení ϵ_i je normální s nulovou střední hodnotou a s konečným rozptylem.

Samozřejmě je možno diskutovat o všech těchto předpokladech. První předpoklad je nejméně omezující a je často přijímán, ale o druhé předpokladu je již možno v praxi často polemizovat. Třetí předpoklad je ještě více omezující. Za tohoto předpokladu je bezpochyby nejhodnější odhad metodou nejmenších čtverců. Často se však setkáváme s problémem odhadu parametrů v modelu kde není splněn třetí nebo dokonce ani druhý předpoklad. Bývá to způsobeno buď tím, že chyba ϵ nemá normální rozložení (často se jedná o rozložení s těžkými chvosty) nebo se jedná o veličinu, která je kontaminována nějakým jiným rozdělením. Nemusí se dokonce ani jednat o symetrické rozložení.

K řešení tohoto problému v modelu parametru polohy a v regresním modelu byly navrženy různé robustní metody.

Práce se zabývá jednak konstrukcí ale i statistickými vlastnostmi regresních α -kvantilů a odhadů založených na těchto regresních α -kvantilech. K důkazu jsou použity různé teoretické výsledky, především související s prací D.Pollarda [18] o vlastnostech empirických procesů indexovaných množinami (Vapnik-Cervoněnkisovy třídy).

Mějme nelineární regresní model

$$y_i = g(x_i, \theta) + \epsilon_i \quad i=1, \dots, n \quad (1)$$

kde $g(x, \theta)$ je spojitá funkce vektorových parametrů $x \in \mathbb{R}^q$, $\theta = (\theta_0, \theta_1, \dots, \theta_p)' \in \mathbb{R}^{p+1}$, kde Θ je kompaktní množina.

Protože uvažujeme model s aditivní chybou ϵ je pro konstrukci kvantilů nutné aby regresní model obsahoval také aditivní neznámý parametr. Pokud tomu tak není je nutno pro konstrukci regresních kvantilů tento parametr přidat k regresní funkci.

Přistupme nyní k vlastnímu problému. Podobně jako R.Koenker a G.Bassett [12] v lineárním modelu definujeme regresní kvantil v modelu (1) (viz. Procházka [20]).

Nejprve označme funkci $\rho_\alpha(\cdot)$:

$$\begin{aligned} \rho_\alpha(z) &= \alpha z && \text{pro } z \geq 0 \\ &= (\alpha - 1)z && \text{pro } z < 0 \end{aligned} \quad (2)$$

a její derivaci zprava

$$\begin{aligned} \psi_\alpha(z) &= \alpha && \text{pro } z \geq 0 \\ &= (\alpha - 1) && \text{pro } z < 0 \end{aligned} \quad (3)$$

Definujme nyní regresní kvantil:

DEFINICE 1.:

Pro $\alpha \in (0, 1)$ nazveme regresním α -kvantilem v modelu nelineární regrese (1) vektor $\hat{\theta}_{\alpha, n}$, který minimalizuje

$$\sum_{i=1}^n \rho_\alpha(y_i - g(x_i, T)) \quad \text{pro } T \in \Theta.$$

Pro takto definované regresní kvantily je v práci odvozena asymptotická lineární representace a z ní plynoucí asymptotická normalita.

Definice regresních kvantilů pak přímo nabízí zobecnění na odhad lineární kombinace regresních kvantilů:

DEFINICE 2.:

Mějme pevné k , konstanty $0 < \alpha_1 < \alpha_2 < \dots < \alpha_k < 1$ a váhy w_1, \dots, w_k , takové, že $w_i \geq 0$ a $\sum w_i = 1$. Pak odhadem θ lineární kombinaci regresních kvantilů nazveme odhad :

$$\hat{\theta}^L = \sum_{i=1}^k w_i \hat{\theta}_{\alpha_i}.$$

Dále se zabývajme možností definice useknutého odhadu. Použijme myšlenku z článku Procházky [20]. Tato definice je zobecněním useknutého odhadu, který zavedli v lineárním modelu Koenker a Bassett [12] na nelineární regresní model. K tomuto účelu použijeme regresní kvantily. Useknutý odhad v modelu nelineární regrese charakterizujeme jako řešení minimalizace :

$$\sum_{i=1}^n I[g(x_i, \hat{\theta}_\alpha) \leq y_i \leq g(x_i, \hat{\theta}_{1-\alpha})] (y_i - g(x_i, T))^2 \quad (4)$$

Vzhledem k $T \in \Theta$.

Tento odhad je již zaveden v článku Procházky [20], ale není zde studováno jeho asymptotické chování. Nejdříve však označme diagonální matici A_n řádu n , jejíž i -tý diagonální prvek je

$$a_{n,i,i} = I[g(x_i, \theta) + F^{-1}(\alpha) \leq y_i \leq g(x_i, \theta) + F^{-1}(1-\alpha)]$$

a matici \hat{A}_n , jejíž diagonální prvky jsou :

$$\hat{a}_{n,i,i} = I[g(x_i, \hat{\theta}_\alpha) \leq y_i \leq g(x_i, \hat{\theta}_{1-\alpha})]$$

Řešení minimalizace výrazu (4) je zřejmě řešením soustavy rovnic

$$D' \hat{A}_n (\bar{y} - g(T)) = 0, \quad (5)$$

kde $\bar{y} = (y_1, \dots, y_n)'$ a $g(z) = (g(x_1, z), \dots, g(x_n, z))'$.

Soustava rovnic (5) může obecně mít více kořenů. Práce ukazuje, že existuje alespoň jeden kořen, který je $n^{1/2}$ konzistentním odhadem θ ; pro libovolný takový kořen je odvozena jeho asymptotická representace a asymptotická normalita.

V této souvislosti definujeme α -useknutý odhad :

DEFINICE 3.:

Nechť $\hat{\theta}_\alpha$ a $\hat{\theta}_{1-\alpha}$ jsou regresní kvantily. Pak α -useknutým odhadem v modelu nelineární regrese nazveme libovolný kořen $\hat{\theta}_{n\alpha}^T$ soustavy rovnic (5), který vyhovuje

$$n^{-1/2} \|\hat{\theta}_{n\alpha}^T - \theta\|_p = O_p(1) \text{ při } n \rightarrow \infty$$

Dříve než přistoupíme k formulaci jednotlivých vět, je nutné klást jisté požadavky na model. Aby vůbec mělo smysl model uvažovat je nutné zajistit aby plán experimentu nebyl degenerovaný:

A1 Nechť pro každých $p+1$ navzájem různých bodů $(y_1, x_1), \dots, (y_{p+1}, x_{p+1})$ existuje nejvýše jedno $\theta \in \Theta$, takové, že $y_1 = g(x_1, \theta), \dots, y_{p+1} = g(x_{p+1}, \theta)$.

Dále je bezpochyby nutné požadovat aby neznámé parametry regresní funkce byly jednoznačně odhadnutelné

A2 $g(x, z)$ ryze monotoní v každé složce z , s parciálními derivacemi, jak prvého, tak i druhého řádu, omezenými konstantou K stejnémerně $x, x \in \mathbb{R}$.

Ikdyž tyto odhady jsou konstruovány jako robustní vzhledem k rozdělení chyb, je samozřejmě nutné uvažovat jistá minimální omezení tohoto rozdělení. podobně jako v lineárním modelu předpokládejme tedy:

A3 $e_i, i=1, \dots, n$ jsou nezávislé, stejně rozdělené náhodné veličiny s hustotou $0 < f(x) < K^*$ pro $x \in \mathbb{R}^p$ a se symetrickou distribuční funkcí $F(x)$. Takovou, že existuje $k > 0$ a $K > 0$ taková, že $k < f'(x) < K$ na nějakém δ -okolí bodu $F^{-1}(a)$, $\delta > 0$.

Předpoklad symetrie rozložení však není zdaleka nutný, je použit pouze pro zjednodušení jednotlivých tvrzení.

Další předpoklad na regresní funkci, často používaný v nelineárním regresním modelu i u odhadu metodou nejmenších čtverců (např. Prakasa Rao [23]), zajišťuje jednoznačnost existence odhadu.

A4 Existují konstanty k_1, k_2 tak, že pro každé $n > n_0$ a $\theta_1, \theta_2 \in \Theta$ je :

$$k_1 |\theta_1 - \theta_2|^2 \leq \frac{1}{n} \sum_{i=1}^n [g(x_i, \theta_1) - g(x_i, \theta_2)]^2 \leq k_2 |\theta_1 - \theta_2|^2.$$

Poslední předpoklad zajišťuje společně s předpokladem A1 nedegenerovanost plánu experimentu, je to obdoba předpokladu běžně používaného v lineárním regresním modelu při konstrukci useknutých odhadů (např. Jurečková [9]) :

A5 Existuje pozitivně definitní matice Q taková, že :

$$Q = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{\partial g(x_i, \tau)}{\partial \tau_j} \right)_{\tau=\theta} \left(\frac{\partial g(x_i, \tau)}{\partial \tau_k} \right)_{\tau=\theta} \right]_{j=0, \dots, p}^{k=0, \dots, p}$$

Nejprve se věnujme regresním kvantilům. Zvolme tedy nějaké pevné $\alpha \in (0, 1)$. Pak lze dokázat tuto větu o konzistenci odhadu regresního α -kvantilu :

VĚTA 4.:

Nechť v modelu (1) platí A1 až A5 pak je

$$\hat{\theta}_n = \hat{\theta}_{\alpha,n} - \theta_\alpha = o_p(1) \quad \text{při } n \rightarrow \infty,$$

kde

$$\theta_\alpha = (\theta_0 + F^{-1}(\alpha), \theta_1, \dots, \theta_p)'.$$

Označme podobně jako Pollard [18]

$$E_{1,\alpha} = e_1 - F^{-1}(\alpha)$$

$$D_n = n^{-1/2} \left[\left(\frac{\delta g(x_i, \theta + \tau)}{\delta \tau_j} \right)_{\substack{i=1, \dots, n \\ k=0, \dots, p}} \right] \quad \text{matici } nx(p+1)$$

$$\Psi(\alpha) = \begin{pmatrix} \psi_\alpha(E_{1,\alpha}) \\ \vdots \\ \psi_\alpha(E_{1,\alpha}) \end{pmatrix}_{i=1, \dots, n}, \quad W_n(\alpha) = D_n' \Psi(\alpha) \quad \text{a} \quad P_n = D_n' D_n$$

Následující věta nám již dává asymptotickou representaci regresních α -kvantilů v modelu (1).

VĚTA 5.:

Nechť v modelu (1) jsou splněny předpoklady A1 až A5. Pak při $n \rightarrow \infty$ platí asymptotická representace

$$n^{1/2} \left(\hat{\theta}_{\alpha,n} - \theta_\alpha \right) = \frac{1}{f(F^{-1}(\alpha))} P_n^{-1} W_n(\alpha) + o_p(1).$$

Důsledkem této věty je však i asymptotická normalita odhadů regresních α -kvantilů :

VĚTA 6.:

Nechť v modelu (1) platí A1 až A5; pak

$$\sqrt{n} (\hat{\theta}_n(\alpha) - \theta_n(\alpha))$$

má asymptoticky normální rozdělení se střední hodnotou 0 a kovarianční maticí :

$$\text{var } \hat{\theta}_\alpha = \frac{\alpha(1-\alpha)}{f^2(F^{-1}(\alpha))} Q^{-1} \quad \text{kde } Q = \lim D_n' D_n$$

Tyto věty nám poskytují možnost odvození asymptotických vlastností různých odhadů parametrů θ konstruovaných pomocí regresních kvantilů. Pro nejjednoduší z nich, 1, odhad (regresní medián), lze tyto věty použít přímo a navíc je to odhad kterým se zabývali i jiní autoři.

Následující věta popisuje asymptotické rozdělení $\hat{\theta}^L$:

VĚTA 7.:

Necht v modelu (1) platí A1 až A5. Pak má $\hat{\theta}^L$ asymptoticky normální rozdělení se střední hodnotou

$$E \hat{\theta}^L = (\theta_0 + \sum_{i=1}^k w_i F^{-1}(\alpha_i), \theta_1, \dots, \theta_p)'$$

a s variánční maticí :

$$\text{var } \hat{\theta}^L = \sum_{i=1}^k \sum_{j=1}^k \frac{w_i w_j (\alpha_i \wedge \alpha_j - \alpha_i \alpha_j)}{f(F^{-1}(\alpha_i)) f(F^{-1}(\alpha_j))} Q^{-1}$$

V praxi se někdy v modelu parametru polohy nebo v lineárním regresním modelu používá Gastwirthův odhad (viz. např. kniha D. Hampla a kol. [4]). Pokud bychom chtěli tento odhad zobecnit na obecný regresní model, tak se nám přímo nabízí použití regresních kvantilů. Sestrojíme tedy $\hat{\theta}^G$ zobecněný Gastwirthův odhad parametru θ nelineárního regresního modelu (1) který definujeme :

$$\hat{\theta}^G = 0.3 \hat{\theta}_{1/3} + 0.4 \hat{\theta}_{1/2} + 0.3 \hat{\theta}_{2/3}$$

Podle věty 7 má za předpokladu A1 až A5 $\hat{\theta}^G$ asymptoticky normální rozdělení se střední hodnotou θ a kovarianční maticí :

$$\text{var } \hat{\theta}_\alpha = \kappa Q^{-1}$$

$$\begin{aligned} \text{kde } \kappa = & \frac{0.02}{f^2(F^{-1}(1/3))} + \frac{0.04}{f^2(F^{-1}(1/2))} + \frac{0.02}{f^2(F^{-1}(2/3))} + \\ & + \frac{0.02}{f(F^{-1}(1/3))f(F^{-1}(1/2))} + \frac{0.02}{f(F^{-1}(1/2))f(F^{-1}(2/3))} + \\ & + \frac{0.01}{f(F^{-1}(1/3))f(F^{-1}(2/3))} \end{aligned}$$

Zabývejme se konečně useknutým odhadem $\hat{\theta}_{n\alpha}^T$ zavedeným v definici 3 k formulování vět o asymptotickém chování odhadu bude nejprve potřeba zavést následující označení:

$$\underline{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_n)', \quad \underline{y} = (y_1, \dots, y_n)', \quad g(z) = (g(x_1, z), \dots, g(x_n, z))'$$

a funkci $\varphi_\alpha(\underline{\varepsilon}) = (\varphi_\alpha(\varepsilon_1), \dots, \varphi_\alpha(\varepsilon_n))'$, kde $\varphi_\alpha(x)$ je funkce Hubrova typu:

$$\varphi_\alpha(x) = \begin{cases} x & F^{-1}(\alpha) \leq x \leq F^{-1}(1-\alpha) \\ F^{-1}(1-\alpha) & x > F^{-1}(1-\alpha) \\ F^{-1}(\alpha) & x < F^{-1}(\alpha) \end{cases}$$

Nyní již konečně můžeme formulovat následující větu:

VĚTA 8.:

Nechť $\hat{\theta}_{\alpha_n}^T$ je α useknutý odhad v modelu (1) z definice 3. Pak za předpokladů A1 až A5 při $n \rightarrow \infty$ je :

$$n^{1/2}(\hat{\theta}_{\alpha_n}^T - \theta) = \frac{1}{1-2\alpha} Q^{-1} D'_n p_\alpha(\xi) + o_p(1)$$

a tedy $n^{1/2}(\hat{\theta}_{\alpha_n}^T - \theta)$ má asymptoticky normální rozdělení

$$N_{p+1}(0, \sigma_T^2(\alpha, F) Q^{-1})$$

$$\text{kde } \sigma_T^2 = \frac{1}{(1-2\alpha)^2} \left\{ \int_{F^{-1}(\alpha)}^{1-F^{-1}(\alpha)} x^2 dF(x) + 2\alpha(F^{-1}(\alpha))^2 \right\}$$

Za zmínku stojí i to, že v speciálním případě lineární regrese tato věta poskytuje asymptotickou representaci useknutého odhadu metodou nejmenších čtverců stejnou jako v lineárním modelu (viz. Ruppert a Carroll [26]).

Další možnost definice useknutého odhadu by mohla být založena na zobecnění definice L-odhadu použité v práci Serflinga (44) pro parametr polohy a jejího zobecnění na lineární regresní model, které navrhl Koenker a Portnoy (13).

Tento odhad lze definovat jako integrál regresních kvantilů vzhledem k vhodné mře na podmnožinách intervalu $[0, 1]$, což je možno chápout jako zobecnění lineární kombinace konečně mnoha regresních kvantilů na nekonečně mnoho.

Navržené odhady, především odhady regresních kvantilů a useknuté odhady mají uplatnění všude tam, kde se vyskytuje nelineární regresní model a kde je nutno počítat s výskytem odlehlych pozorování, nebo s jiným než normálním rozdělením chyb. K ilustraci jejich vlastností je možno použít jednak simulaci nebo reálných dat. Chování těchto odhadů na simulovaných datech v modelu lineární kombinace dvou exponencií je ukázáno v článku Procházky [21]. V práci [22] byly použity příklady z lékařského výzkumu, a to jednak výsledky testu ELISA, který vede na model logistické závislosti tvaru :

$$g(\theta, x) = \theta_0 + 1/(1+\exp(-\theta_1 + \theta_2 x)),$$

dále dva farmakokineticke modely, jednak šíření teofylinu v krvi :

$$g(\theta, t) = \theta_0 + \theta_1 \exp(-\theta_2 t) - \theta_3 \exp(-\theta_4 t)$$

a podobný model vylučování izotopu manganu z těla potkanů.

Na závěr si ještě ukážeme data i výsledky jednoho z praktických modelů použitých v práci a to případu logistické regrese. V následujících dvou tabulkách jsou zobrazeny jednak použitá data ale i hodnoty různých odhadů parametru θ . Použité odhady jsou:

\hat{L}_2 - odhad metodou nejmenších čtverců \hat{L}_1 - odhad metodou nejmenších absolutních odchylek ('regresní medián'), TLS - useknutý odhad metodou nejmenších čtverců a $Q(.1)$, $Q(.9)$ regresní kvantily. Hodnoty s jsou hodnoty minimalizačního kritéria.


Data :

Odhady parametrů :

Řadění	Absorbance	
1	0.920	0.852
2	0.872	0.752
3	0.742	0.736
4	0.433	0.510
5	0.689	0.431
6	0.204	0.271
7	0.106	0.187
8	0.049	0.109

odhad	S	θ_2	θ_1	θ_0
\hat{L}_2	0.1279	0.6689	3.0775	
\hat{L}_1	0.5080	0.6902	2.8503	
TLS	0.0208	0.6518	2.8119	
$Q(.1)$	0.1845	0.6430	2.8032	-0.0825
$Q(.9)$	0.3078	0.6576	2.9287	0.0455

Tyto naměřené hodnoty a odhadnuté regresní funkce jsou zobrazeny v následujícím grafu.



V grafu je zřetelně vidět, že \hat{L}_2 -odhad je výrazně vychýlen pozorováním v koncentraci 5, dokonce tak, že se blíží odhadu horního regresního kvantilu. ostatní odhady již nejsou zdaleka tak citlivé.

LITERATURA :

- [1] D.W.K. Andrews : Consistency in Nonlinear Econometric Models : a Generic Uniform Law of Large Numbers. *Econometrica* 55 (1987).
- [2] Y. Bard: *Nonlinear Parameter Estimation*. Academic Press, N.York 1974
- [3] S.van de Geer : *Regression Analysis and Empirical Processes*. doktorská disertační práce-Leiden (1987)

- [4] F.R.Hampel, E.M.Ronchetti, P.J.Rousseeuw and W.A.Stahel : *Robust Statistics: The Approach Based on Influence Function.* J.Wiley, 1986
- [5] S.Heiler and R.Willers : *Asymptotic Normality of R-Estimates in the Linear Model.* Statistics 19 (1988), 2, 173 -184.
- [6] A.V.Ivanov : *Asymptotické skoje razloženije dija raspredelenija očeky najmenších kvadratov parametra nelinéjnoj regresii.* Téorija verojatnostej i jeje primeněnija 21 (1976), 571-583.
- [7] J.Jurečková : *Asymptotic Relations of M-Estimates of Location.* Math. Operationsforsch. Statist., Ser. Statistics 11 (1980) 1 61.
- [8] J.Jurečková : *Trimmed Polynomial Regression.* Commentationes Mathematicae Universitatis Carolinae, 24, 4, (1983), 579-607.
- [9] J.Jurečková : *Regression Quantiles and Trimmed Least Squares Estimator under a General Design.* Kybernetika 20 (1984), 5.
- [10] J.Jurečková : *Asymptotic Representation of L-estimators and their Relations to M-estimators.* Sequential Analysis, 5 (1986), 4.
- [11] R.I.Jenrich : *Asymptotic Properties of Non-linear Least Squares Estimators.* The Annals of Mathematical Statistics 40 (1969), 2.
- [12] R.Koenker & G.Bassett: *Regression Quantiles.* Econometrica 46(1978)
- [13] R.Koenker and S.Portnoy : *L-estimation for Linear Models.* American Statistical Association 82 (1987), 339, 851-857.
- [14] H.Läuter : *Note on the Strong Consistency of the Least Squares Estimator in Nonlinear Regression.* Statistics, 20, (1989) 2.
- [15] F.Leise and I.Vajda : *M-estimators in Regression with i.i.d. Errors.* V tisku. [16] W.Oberhofer : *The Consistency of Nonlinear Regression Minimizing the l_1 -norm.* The Annals of Statistics 10 (1982), 1, 316-319.
- [17] D.Pollard : *Asymptotics for Least Absolute Deviation Regression Estimators.* J.Amer.Statist.Assoc. 82 (1987), 851-857.
- [18] D.Pollard : *Empirical Processes Theory and Applications.* IMS Lecture Notes (1989).
- [19] J.L.Powell : *Least absolute deviations estimation for the censored regression model.* Journal of Econometrics 25 (1984).
- [20] B.Procházka : *Regression Quantiles and Trimmed Least Squares Estimator in the Nonlinear Regression Model.* Computational Statistics & Data Analysis 6 (1988) 358-391.
- [21] B.Procházka : *Useknuté odhadov v modelu nelineárni regrese.* ROBUST 86 JČSME.
- [22] B.Procházka : *Useknuté odhadov v modelu nelineárni regrese.* Kandidátská disertační práce MFF UK Praha 1992.
- [23] B.L.S.Prakasa Rao : *Asymptotics Theory of Statistical Inference.* New York, J.Wiley 1987.
- [24] G.D.Richardson : *Consistent l_1 -estimators in Nonlinear Regression for Noncompact Parameter Space.* Sankhya: The Indian Journal of Statistics 49 Series A (1987) 3 377-387.
- [25] R.J.Serfling : *Approximation Theorems of Mathematical Statistics.* New York, J.Wiley 1980.
- [26] D.Ruppert and R.J.Carroll : *Trimmed Least-squares Estimation in the Linear Model.* J.Amer.Statist.Assoc. 75 (1980), 828-838.
- [27] Andrew A. Weiss : *Estimating Nonlinear Dynamic Models Using Least Absolute Error Estimation.* Econometric theory 7 (1991).
- [28] K.Zvára : *Regresní Analýza.* Academia Praha (1989).