

Jednoduchý fuzzy regresní model

A simple fuzzy regression model

Zdeněk Půlpán

Jiří Kulička

Adresa: Prof. RNDr. PhDr. Zdeněk Půlpán, CSc.

Na Brně 1952/39, 500 09 Hradec Králové 9

Mgr. Jiří Kulička, PhD

Univerzita Pardubice, DFJP, Studentská 95, 532 10 Pardubice

E-mail: zdenek.pulpan@uhk.cz,

Zdenek.Pulpan@klikni.cz

Abstrakt: Ukážeme řešení problému lineární fuzzy regrese. Využijeme principy teorie fuzzy množin a problematiku odhadu lineární závislosti výstupní proměnné Y navstupní proměnné X . Předpokládáme při tom, že vstupní proměnná X není fuzzy, ale "ostrá" hodnota, měřená s vyšší přesností než výstupní proměnná Y , která bude fuzzyfikována. V úvaze o řešení bude problém postupně formálně rozšiřován až k situaci, kdy v modelu lineární závislosti $Y = A + BX$ jsou proměnné A, B, Y považovány za trojúhelníková fuzzy čísla.

Klíčová slova: Lineární fuzzy regrese, použití trojúhelníkových fuzzy čísel.

Abstract: We will show solution of the problem of fuzzy linear regression. We will use the principles of fuzzy set theory to solve the problem of estimating the linear dependence of the output variable Y on the input variables X . We assume the input variable X as the fuzzy variable, but with the "real" value, measured with greater accuracy than the output variable Y , which was fuzzyfying. In the problem solving we consider the possibilities in which we will the situation gradually formally extend to the situation where in the model of linear relationship $Y = A + BX$ are the variables A, B, Y as triangular fuzzy numbers represented.

Keywords: Linear fuzzy regression, using triangular fuzzy numbers.

1. Úvod

V práci [6] jsme uvedli použití lineární regrese a logistické regrese k odhadu závislostí dvou proměnných z empirických zjištění. Zde ukážeme použití teorie fuzzy množin k odhadu lineární závislosti za podmínky, že o charakteru vztahu dvou veličin máme jen málo informací. Jak bude dále vidět, je několik možných přístupů k řešení problému odhadu závislosti jedné proměnné na lineární kombinaci zbývajících proměnných, které využívají teorie fuzzy množin.

Předpokládejme, že vztah spojitých náhodných veličin X a Y máme dokumentován měřeními tak, že získané dvojice (x_i, y_i) , $i = 1, 2, \dots, N$, jsou odpovídajícími hodnotami uvedených veličin měřených současně na N statistických jednotkách. Uvažujme situaci, kdy není zaručeno splnění Gauss – Markovových podmínek pro odvození statistických vlastností odhadu předpokládaného vztahu mezi veličinami X a Y , např. ve tvaru lineární závislosti $Y = \alpha + \beta x + \varepsilon$, kde ε je chyba odhadu. V odůvodněných a dostatečně obecných případech je možné se opřít jen o představu, že veličina X není náhodná (s hlediska teorie fuzzy množin uvažujeme, že je veličinou ostrou – anglicky crisp), ale veličina Y je neostrá, tedy fuzzy; označme proto veličinu Y obvyklým způsobem jako fuzzy náhodnou veličinu ([3], [4], [5]) znakem \underline{Y} a konstruuje pro ní vhodnou věrohodnostní funkci μ_Y . “Odůvodněným případem” rozumíme například situaci, kdy hodnoty veličiny X jsou odhadnutelné s větší přesností než hodnoty veličiny Y a tak každá z naměřených hodnot x_i můžeme změřit více hodnot veličiny Y :

$$x_i \rightarrow y_{i1}, y_{i2}, \dots, y_{in_i}, i = 1, 2, \dots, N; (1)$$

při tom nejsme schopni předpovědět ty prozdělení náhodné veličiny $Y = Y(x)$. Víra v možnost spojitě přibližného odhadu hodnot veličiny Y z hodnot veličiny X (tedy víra v odhad hodnoty druhé proměnné $Y(x)$ jako fuzzy množiny $\underline{Y}(x)$, která by měla být fuzzy číslem) musí vyplývat z naší zkušenosti. Situaci interpretujme itak, že hodnoty veličiny X chápeme jako ostré vstupy, hodnoty veličiny $Y(x)$ jako neostré, fuzzy výstupy. Jen výstupní hodnoty budou v našem modelu charakterizované neurčitostí popsatelnou fuzzy množinami. Nejjednodušším způsobem je ten, že odhad parametrů α, β předpokládané závislosti budeme nejprve realizovat ostrými (ne-fuzzy) hodnotami a, b z dvojic (x_i, y_i) , $i = 1, 2, \dots, N$, metodou nejmenších čtverců tak, aby aproximující funkce $\hat{y}(x) = a + bx$ splňovala podmínku minimalizace výrazu

$$Q(a, b) = \sum_{i=1}^N \sum_{j=1}^{n_i} (y_{ij} - \hat{y}(x_i))^2 = \sum_{i=1}^N \sum_{j=1}^{n_i} (y_{ij} - a - bx)^2 \quad (2)$$

v intervalu proměnnosti veličiny X . Dostaneme tak pro $\hat{y}(x)$ vztah

$$\hat{y}(x) = \bar{y} + b(x - \bar{x}); \text{ kde } \bar{x} = \frac{1}{n} \sum_{i=1}^N x_i n_i; \bar{y} = \frac{1}{n} \sum_{i,j} y_{ij}; n = \sum_{i=1}^N n_i; \quad (3)$$

$$b = \frac{n \sum_{i,j} x_i y_{ij} - \sum_i n_i x_i \sum_{i,j} y_{ij}}{n \sum_i x_i^2 n_i - (\sum_i x_i n_i)^2}.$$

K popisu závislé veličiny Y můžeme použít symetrické trojúhelníkové fuzzy číslo $\underline{Y}(x)$ s věrohodnostní funkcí $\mu_Y(x, y)$:

$$\mu_Y(x, y) = 1 - \frac{1}{c} |y - \hat{y}(x)|, \text{ když } |y - \hat{y}(x)| \leq c \quad (4)$$

= 0, jinak.

Kladná konstanta c je mírou rozptýlenosti hodnot náhodné veličiny $Y(x)$ pro pevná x z intervalu proměnnosti veličiny X . Hodnotu konstanty c můžeme určit buď expertně nebo výpočtem z dvojic naměřených hodnot (x_i, y_i) například takto:

$$c_i = \max_j |y_{ij} - \hat{y}(x_i)| \quad (5)$$

$$c = \frac{1}{N} \sum_{i=1}^N c_i$$

Je-li $c = 0$ (nebo "blízké" 0), pak naměřené hodnoty veličiny $Y(x)$ jsou bez registrovaného rozptýlení okolo hodnot $\hat{y}(x_i)$; je pak otázkou, zda představa veličiny $Y(x)$ jako fuzzy náhodné $\underline{Y}(x)$ je oprávněná. Předchozí výpočet je podmíněným, že variabilita hodnot y_{ij} okolo hodnot $\hat{y}(x_i)$ je v celém rozsahu proměnnosti veličiny X stejná (kladné odchylky od $\hat{y}(x_i)$ jsou stejně možné jako záporné v přibližně stejných hodnotách); taktou važíme také když o možných odchylkách nemáme dostatek konkrétnějších informací. Výsledkem úvahy je pak "rozmazaný" (fuzzy-) odhad lineární regrese funkce. Je zřejmé, že uvedený postup lze zobecnit na obdobný případ vztahu více proměnných.

Poznámka 1: Není-li možné předpokládat rozptýlenost hodnot y_{ij} okolo $\hat{y}(x_i)$, nezávislou na i , pak pro každé i konstruuje předpověď $\tilde{Y}(x_i)$, kde ve vztahu pro μ_Y nahrazujeme univerzální konstantu c hodnotou c_i , například podle (5).

Poznámka 2: Je-li veličina X diskrétní, pak určitou předpověď hodnoty $Y(x)$ můžeme chápat jako fuzzy množinu $\tilde{Y}(x)$ (která by měla být ovšem fuzzy číslem).

Příklad 1. Máme k dispozici měření, zaznamenané v Tab. 1. Úkolem je stanovit předpověď hodnoty $Y(5)$ (která v tabulce měření uvedena není).

Tab. 1. Hodnoty měřených veličin X, Y k Příkladu 1.

i	x_i	y_{ij}	$\hat{y}(x_i)$	$ y_{ij} - \hat{y}(x_i) $	$\max_j y_{ij} - \hat{y}(x_i) $
1	1	1; 2; 4	2,51	1,51; 0,51; 1,49	1,51
2	3	3; 5	4,01	1,01; 0,99	1,01
3	4	4; 7	4,76	0,76; 2,24	2,24
4	6	4; 5; 9	6,26	4,26; 1,26; 2,74	4,26

Dosažení hodnot z Tab. 1 do vztahů (3) dostaneme postupně:

$$n = 10; \quad N = 4;$$

$$\bar{x} = 0,1 \cdot (3 \cdot 1 + 2 \cdot 3 + 2 \cdot 4 + 3 \cdot 6) = 3,5; \quad \bar{y} = 0,1 \cdot (1 + 2 + 4 + 3 + 5 + 4 + 7 + 4 + 5 + 9) = 4,4$$

$$b = \frac{10 \cdot 183 - 35 \cdot 44}{10 \cdot 161 - 35^2} = \frac{290}{385} = 0,753;$$

$$\hat{y}(x) = 4,4 + 0,75 (x - 3,5) = 1,76 + 0,75 x \quad (6)$$

Předpověď ostré hodnoty v bodě $x = 5$ je $\hat{y}(5)$, povyčíslení je $\hat{y}(5) = 5,51$; pro náš případ si ale určíme $c = \frac{1}{4} \sum_{i=1}^4 c_i = 2,25$. Hodnoty veličiny $Y(x)$ budou reprezentovány trojúhelníkovým fuzzy číslem $\tilde{Y}(x)$; zachycují neurčitost předpovědi prostřednictvím věrohodnostní funkce $\mu_Y(x, y)$:

$$\mu_Y(x, y) = 1 - \frac{1}{2,25} |y - 1,76 - 0,75x|, \text{ když } |y - 1,76 - 0,75x| \leq 2,25; \quad (7)$$

= 0, jinak.

Pro $X = 5$ je podle předchozího vztahu $\tilde{Y}(5)$ dáno věrohodnostní funkcí


$$\mu_Y(x, 5) = 1 - 0,44 \cdot |y - 5,51| \text{ když } 3,26 \leq y \leq 7,76 \quad (8)$$

= 0 jinak.

Fuzzy množina $\tilde{Y}(5)$ je zobrazena na Obr. 1. Podle vztahu (8) je věrohodnost výroku “ $Y(5) = 3$ ” rovna nule, věrohodnost výroku “ $Y(5) = 5$ ” je rovna 0,78. (Viz také Obr. 1.)




Podobně určíme věrohodnost výroku “ $Y(2) = 4$ ” z vztahu (7) dosazením $x = 2, y = 4$; dostaneme přibližně hodnotu $\mu_Y(2, 4) = 0,67$. Graf jednoduché fuzzy regrese závislosti Y na X je na Obr. 2.

Obr. 1. Obrázek věrohodnostní funkce fuzzy čísla $\tilde{Y}(5)$ k Příkladu 1.



Obr. 2. Jednoduchá fuzzy regrese k Příkladu 1. První obrázek představuje horní odhad fuzzy regresní funkce, druhý obrázek je grafem dolního odhadu fuzzy regresní funkce (v bodech (x, y) tohoto grafu je věrohodnostní funkce $\mu_Y(y)$ rovna nule, pro body s vyšším y

jsou však její hodnoty nenulové až do bodu horního odhadu – ovšem přístojněm x), třetí graf je grafem fuzzy regresní funkce, je to vlastně graf souřadnic (x,y) bodů pro něž je věrohodnostní funkce $\mu_Y(y) = 1$ (Viz také Obr.1.)



2. První fuzzy model

Upravmenyní uvedenou metodou tak, že ve vyjádření příslušného regresního odhadu budou parametry a , b trojúhelníkovými fuzzy čísly a veličina X bude "ostrá". Pak výsledný odhad proměnné Y musí být také trojúhelníkovým fuzzy číslem (lineární kombinací trojúhelníkových fuzzy čísel je opět trojúhelníkové fuzzy číslo).

Předpokládejme tedy, že hledáme metakový regresní vztah tvaru $\underline{Y} = \underline{A} + \underline{B}X$, kde \underline{A} , \underline{B} , \underline{Y} jsou trojúhelníková fuzzy čísla a veličina X je ostrá:

$$\mu_A(y) = 1 - \frac{|p_0 - y|}{c_0}, \text{ když } p_0 - c_0 \leq y \leq p_0 + c_0; c_0 > 0; \quad (10)$$

= 0 ; jinak,

$$\mu_B(y) = 1 - \frac{|p_1 - y|}{c_1}, \text{ když } p_1 - c_1 \leq y \leq p_1 + c_1; c_1 > 0; \quad (11)$$

= 0 ; jinak,

$$\mu_Y(y) = 1 - \frac{|p_0 + p_1 x - y|}{c_0 + c_1 |x|}, \text{ když } p_0 + p_1 x - c_0 - c_1 |x| \leq y \leq p_0 + p_1 x + c_0 + c_1 |x|$$

= 0 ; jinak, (12)

Volme $\alpha \in (0; 1)$ a stanovme podmínky pro to, aby $\mu_Y(y) \geq \alpha$. (Pro fuzzy číslo \underline{Y} volíme tak jeho α -řez jako ostrou množinu α -přípustných hodnot y .) Vyjdeme-li zevztahu (12) pro $\mu_Y(y)$, dostaneme podmínku pro y vztahu:

$$1 - \frac{|p_0 + p_1 x - y|}{c_0 + c_1 |x|} \geq \alpha \quad (13)$$

Jednoduchou úpravou a odstraněním absolutní hodnoty získáme dvě základní nerovnosti:

$$y \geq p_0 + p_1 x - (1 - \alpha)(c_0 + c_1 |x|) \quad (14a)$$

$$y \leq p_0 + p_1 x + (1 - \alpha)(c_0 + c_1 |x|) \quad (14b)$$

Zevšech možných regresních vztahů vybíráme ten, který minimalizuje "rozmazanost" výstupní fuzzy množiny \underline{Y} . "Rozmazanost" fuzzy množiny \underline{Y} je $c_0 + c_1 |x|$ pro každou dvojici měření (x, y) . Požadavek minimalizace "rozmazanosti" vztahujeme pro všechna měření k výrazu Q tvaru (15). Výraz (15) představuje součet "rozmazaností" všech $\underline{Y}(x)$:

$$Q = N \cdot c_0 + c_1 \sum_{i=1}^N |x_i| \quad (15)$$

Nalezení vhodných parametrů $c_0 > 0$, $c_1 > 0$ a p_0, p_1 , které splňují (14a) a (14b) zapodmínky minimalizace funkce $Q = Q(c_0, c_1)$ z (15) tak představuje řešení úlohy lineárního programování. Úloha se tak může řešit standardními metodami úloh lineárního programování.

Příklad 2. Použijme data z *Příkladu 1* a sestavme podmínky úlohy lineárního programování pro určení hodnot parametrů c_0, c_1 a p_0, p_1 z minimalizace funkce $Q = Q(c_0, c_1)$. Volme při tom $\alpha = 0,75$. Postupně dostaneme soustavu nerovností nejprve dosazením do (14a) a pak také do (14b), nerovnosti tvoří podmínku pro přípustná řešení:

a) první část nerovnic:

$$x=1: \quad p_0 + p_1 - 0,25c_1 \leq 1$$

$$p_0 + p_1 - 0,25c_1 \leq 2$$

$$p_o + p_1 - 0,25c_1 \leq 4$$

$$x=3: p_o + 3p_1 - 0,25c_o - 0,75c_1 \leq 3$$

$$p_o + 3p_1 - 0,25c_o - 0,75c_1 \leq 5$$

$$x=4: p_o + 4p_1 - 0,25c_o - c_1 \leq 4$$

$$p_o + 4p_1 - 0,25c_o - c_1 \leq 7$$

$$x=6: p_o + 6p_1 - 0,25c_o - 1,5c_1 \leq 4$$

$$p_o + 6p_1 - 0,25c_o - 1,5c_1 \leq 5$$

$$p_o + 6p_1 - 0,25c_o - 1,5c_1 \leq 9$$

b) druháčástnerovnic:

$$x=1: p_o + p_1 + 0,25c_o + 0,25c_1 \geq 1$$

$$p_o + p_1 + 0,25c_o + 0,25c_1 \geq 2$$

$$p_o + p_1 + 0,25c_o + 0,25c_1 \geq 4$$

$$x=3: p_o + 3p_1 + 0,25c_o + 0,75c_1 \geq 3$$

$$p_o + 3p_1 + 0,25c_o + 0,75c_1 \geq 5$$

$$x=4: p_o + 4p_1 + 0,25c_o + c_1 \geq 4$$

$$p_o + 4p_1 + 0,25c_o + c_1 \geq 7$$

$$x=6: p_o + 6p_1 + 0,25c_o + 1,5c_1 \geq 4$$

$$p_o + 6p_1 + 0,25c_o + 1,5c_1 \geq 5$$

$$p_o + 6p_1 + 0,25c_o + 1,5c_1 \geq 9$$

přisoučasnéminimalizacifunkce $Q(c_o, c_1) = 4c_o + 14c_1$

.Zjednodušenítéto soustavy získáme Tab. 2, použitelnou již pro řešení některou z metod lineárního programování.

Výsledkem řešení uvedené úlohy minimalizace funkce Q namnožině přípustných hodnot pro p_o, p_1 a nezáporná c_o, c_1 jsou postupně $Q_{\min} = 58, p_o = p_1 = 1, c_o = 11, c_1 = 1$.

Tento model předpovídá hodnotu proměnné Y v bodě $x = 5$ jako trojúhelníkové fuzzy číslo $\widetilde{Y}(5)$ (viz Obr. 3) s věrohodnostní funkcí danou čísly p_o, p_1, c_o, c_1 v obecném tvaru

$$\mu_Y(y) = 1 - \frac{|p_o + 5p_1 - y|}{c_o + 5c_1}, \text{ když } p_o + 5p_1 - c_o - 5c_1 \leq y \leq p_o + 5p_1 + c_o + 5c_1,$$

= 0; jinak;


tedy v našem případě to je

$$\mu_Y(y) = 1 - \frac{|6-y|}{16}; \quad -10 \leq y \leq 22,$$

= 0; jinak.

“Rozmazanost” výsledného fuzzy čísla je velká.

Obr. 3. Obraz fuzzy čísla $\underline{Y}(5)$ k Příkladu 2.



Tab.2 Tabulka pro numerické řešení úlohy lineárního programování z Příkladu 2.

$X =$	p_0	p_1	c_0	c_1	znaménko	absolutní člen
1	1	1	--0,25	--0,25	\leq	1
3	1	3	--0,25	--0,25	\leq	3
4	1	4	--0,25	--0,25	\leq	4
6	1	6	--0,25	--0,25	\leq	4
1	1	1	0,25	0,25	\geq	4
3	1	3	0,25	0,75	\geq	5
4	1	4	0,25	1,00	\geq	7
6	1	6	0,25	1,50	\geq	9
Q =	0	0	4	14	minimalizace	

2. Druhý fuzzy model

Ještě dále zobecníme naše předpoklady. Dosud jsme uvažovali, že měřená veličina Y je ostrá a její odhad je fuzzy číslo \tilde{Y} . Nyní budeme předpokládat, že naměřené hodnoty y_{ij} jsou realizacemi jistého fuzzy čísla \underline{Y}_i s věrohodnostní funkcí (16):

$$\mu_{Y_i}(y) = 1 - \frac{|\bar{y}_i - y|}{e_i}; e_i > 0; \text{ když } \bar{y}_i - e_i \leq y \leq \bar{y}_i + e_i$$

$$= 0 \text{ ;jinak.} \quad (16)$$

(Ve (16) je \bar{y}_i aritmetický průměr z hodnot $y_{ij}, j=1, 2, \dots, n_i$.)

Kladná hodnota e_i definuje “přesnost” měření veličiny Y . V případě, že máme k určité hodnotě x_i naměřeno více hodnot y_{ij} druhé (výstupní) proměnné Y , můžeme konstantu e_i určit například podle

$$e_i = \max_j |y_{ij} - \bar{y}_i|, \quad i = 1, 2, \dots, N. \quad (17)$$

Pro fuzzy výstup \underline{Y} z regresní rovnice $\underline{Y} = \underline{A} + \underline{B}X$ pak máme věrohodnostní funkci (12). Fuzzy regresní odhad \tilde{Y} musí splňovat podmínku pro inkluzi α – řezů fuzzyfikovaných výstupních hodnot \underline{Y}_i a regresního odhadu $\tilde{Y}_i = \underline{A} + \underline{B}x_i$ ve tvaru


$$\underline{Y}_i^{\alpha_i} \subseteq \tilde{Y}_i^{\alpha}, \text{ tj. } \alpha_i \geq \alpha \text{ pro všechna } i. \quad (18)$$

Nejlepší hodnotou α (snažíme se, aby bylo co největší) pak je

$$\alpha = \min_i \{\alpha_i\}. \quad (19)$$

Při tom ale také požadujeme, aby “rozmazanost” regresního odhadu byla co nejmenší, tedy opět jde o minimalizační funkci (15). (Viz Obr. 4.)

Obr. 4. Komentář ke vztahu (18). Vyplněná část zobrazuje věrohodnostní funkci fuzzy množiny \underline{Y}_i a nevyplněná fuzzy množinu, která reprezentuje hodnoty fuzzy regresní funkce $\tilde{Y}(x_i)$.



Rozepíšeme-li podmínku (18) pro uvedené α -řezy, máme pro všechny dvojice naměřených hodnot (x_i, y_{ij}) dva druhy nerovnic:

$$y_{ij} \geq p_0 + p_1 x_i - (1 - \alpha)(c_0 + c_1 x_i) + (1 - \alpha)e_i$$

$$y_{ij} \leq p_0 + p_1 x_i + (1 - \alpha)(c_0 + c_1 x_i) - (1 - \alpha)e_i; \text{ pro všechna } i, j. \quad (20)$$

Soustava nerovnic (20) lze zjednodušit na tvar (21):

$$\min_j \{ y_{ij} \} \geq p_0 + p_1 x_i - (1 - \alpha)(c_0 + c_1 x_i) + (1 - \alpha)e_i$$

$$\max_j \{ y_{ij} \} \leq p_0 + p_1 x_i + (1 - \alpha)(c_0 + c_1 x_i) - (1 - \alpha)e_i; \text{ pro všechna } i. \quad (21)$$

Opět se jedná o úlohu lineárního programování; zapodmínek (12.21) hledáme minimum funkce $Q = Q(c_0, c_1)$. Ukážeme si to na konkrétním příkladě.

Příklad 3. Pokusme se aplikovat předchozí teorii na data z *Příkladu 1.* (Viz Tab. 1.)

Protože předpokládáme, že naměřené výstupní hodnoty jsou realizací trojúhelníkových fuzzy čísel (16), určíme nejprve hodnoty jejich parametrů e_i podle (17):

$$i = 1: \bar{y}_1 = 2,33; e_1 = 1,67$$

$$i = 2: \bar{y}_2 = 4,00; e_2 = 1,00$$

$$i = 3: \bar{y}_3 = 5,50; e_3 = 1,50$$

$$i = 4: \bar{y}_4 = 6,00; e_4 = 3,00.$$

Volíme stejného α jako v předcházejících případech $\alpha = 0,75$. Dosazením dat z Tab. 1 dostáváme soustavu nerovnic ve tvaru:

$$1 \geq p_0 + p_1 - 0,25 \cdot (c_0 + c_1) + 0,25 \cdot 1,67$$

$$3 \geq p_0 + 3p_1 - 0,25 \cdot (c_0 + 3c_1) + 0,25 \cdot 1,00$$

$$4 \geq p_0 + 4p_1 - 0,25 \cdot (c_0 + 4c_1) + 0,25 \cdot 1,50$$

$$4 \geq p_0 + 6p_1 - 0,25 \cdot (c_0 + 6c_1) + 0,25 \cdot 3,00$$

$$4 \leq p_0 + p_1 + 0,25 \cdot (c_0 + c_1) - 0,25 \cdot 1,67$$

$$5 \leq p_0 + 3p_1 + 0,25 \cdot (c_0 + 3c_1) - 0,25 \cdot 1,00$$

$$7 \leq p_0 + 4p_1 + 0,25 \cdot (c_0 + 4c_1) - 0,25 \cdot 1,50$$

$$9 \leq p_0 + 6p_1 + 0,25 \cdot (c_0 + 6c_1) - 0,25 \cdot 3,00$$

Řešení této soustavy nerovnic (viz také Tab.3) získáme přípustné hodnoty pro p_0, p_1, c_0, c_1 . Hodnoty optimální získáme z nich výběrem těch, které minimalizují funkci $Q = 4c_0 + 14c_1$. Jsou to při $Q_{\min} = 50$ hodnoty $p_0 = p_1 = 1; c_0 = 9; c_1 = 1$, které určují $\widetilde{Y}(5)$ věrohodnostní funkci $\mu_Y(y)$ ve tvaru

$$\mu_Y(y) = 1 - \frac{|p_0 + 5p_1 - y|}{c_0 + 5c_1} = 1 - \frac{|6 - y|}{14}, \text{ když } -8 \leq y \leq 20,$$

= 0; jinak;

“Rozmazanost” tohoto fuzzy čísla je o něco menší.

Tab. 3. Tabulka pro řešení úlohy lineárního programování z Příkladu 3.

$X =$	p_0	p_1	c_0	c_1	znaménko	abs. člen
1	1	1	-0,25	-0,25	\leq	0,58
3	1	3	-0,25	-0,75	\leq	2,75
4	1	4	-0,25	-1,00	\leq	3,63
6	1	6	-0,25	-1,50	\leq	3,25
1	1	1	0,25	0,25	\geq	4,42
3	1	3	0,25	0,75	\geq	5,25
4	1	4	0,25	1,00	\geq	7,38
6	1	6	0,25	1,50	\geq	9,75
Q =	0	0	4	14	minimalizace	

Závěr

Uvedené dva fuzzy modely lineární regrese využívají důležitou vlastnost trojúhelníkových fuzzy čísel (jejich lineární kombinace je opět fuzzy číslo). Omezuje se tím však obecnost metody, protože se tak dají řešit jen problémy, kde obstojí předpoklad, že závislá veličina má všude stejnou variabilitu. Výhodou spočívá v možnosti užití standardních algoritmů řešení úlohy lineárního programování. Nevýhodou je vysoká “rozmazanost” takových fuzzy odhadů.

Literatura

- [1] Ross, T., J.: *Fuzzy logic with engineering applications*, second edition, J. Wiley & Sons, Ltd., The Atrium, Southern Gate, Chichester, West Sussex PO 198SQ, England, June 2005
- [2] Klir, G., J., Yuan, Bo: *Fuzzy Sets and Fuzzy Logic: Theory and Applications*, Prentice Hall, Upper Saddle River, 1995
- [3] Kwakernaak, H.: Fuzzy Random Variables I and II. *Inf. Sci. (USA)*, Vol. 15: 1–29, 1979
- [4] Viertl, R.: Univariate Statistical Analysis with Fuzzy Data, *Computational Statistics & Data Analysis*, Vol. 51, Issue 1, 2006, pp 133 – 147, ISSN: 0167 – 9473

[5] Wang, G., Yhang, Y.: The Theory of Fuzzy Stochastic Processes, *Fuzzy Sets and Systems*, Vol.51, pp 161 – 178, 1992, ISSN 0165 –0114

[6] Půlpán, Z.: *K problematice zpracování empirických šetření v humanitních vědách*, Academia, Praha 2004

ⁱ Gauss – Markovovy podmínky předpokládají nezávislost náhodné veličiny $Y(x_i)$ na $Y(x_j)$ pro každé $x_i \neq x_j$ a to, že náhodná veličina $Y(x)$ má normální (Gaussovo) rozdělení $N(EY(x); \sigma^2)$, kde σ^2 je rozptyl, nezávislý na x , regresní funkce $EY(x)$ je obecně funkcí v intervalu proměnnosti uvažované náhodné veličiny X .