

UNIVERZITA KOMENSKÉHO V BRATISLAVA  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**MIERY DOBREJ ZHODY ZALOŽENÉ  
NA ŠTATISTICKÝCH VZDIALENOSTIACH**

DIPLOMOVÁ PRÁCA

Bratislava 2013

Bc. Miloš Bella

UNIVERZITA KOMENSKÉHO V BRATISLAVA  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**MIERY DOBREJ ZHODY ZALOŽENÉ  
NA ŠTATISTICKÝCH VZDIALENOSTIACH**

DIPLOMOVÁ PRÁCA

Študijný program: Ekonomická a finančná matematika  
Študijný odbor: Aplikovaná matematika 1114  
Školiace pracovisko: Katedra aplikovanej matematiky a štatistiky  
Školiteľ: Mgr.Ján Mačutek, PhD.

Bratislava 2013

Bc. Miloš Bella



37393348

Univerzita Komenského v Bratislave  
Fakulta matematiky, fyziky a informatiky

## ZADANIE ZÁVEREČNEJ PRÁCE

**Meno a priezvisko študenta:** Bc. Miloš Bella

**Študijný program:** ekonomická a finančná matematika (Jednoodborové štúdium, magisterský II. st., denná forma)

**Študijný odbor:** 9.1.9. aplikovaná matematika

**Typ záverečnej práce:** diplomová

**Jazyk záverečnej práce:** slovenský

**Názov:** Miery dobrej zhody založené na štatistických vzdialenosťach

**Ciel:** Aplikácie niektorých štatistických vzdialenosťí (entropie, divergencie) na testovanie zhody medzi modelmi a dátami. Využitie náhodných čísel a simulovaných p-hodnôt.

**Vedúci:** Mgr. Ján Mačutek, PhD.

**Katedra:** FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky

**Vedúci katedry:** prof. RNDr. Daniel Ševčovič, CSc.

**Dátum zadania:** 25.01.2012

**Dátum schválenia:** 06.09.2012

prof. RNDr. Daniel Ševčovič, CSc.

garant študijného programu

.....  
študent

.....  
vedúci práce

## **Prehlásenie**

Čestne prehlasujem, že som túto diplomovú prácu vypracoval samostatne s použitím citovaných zdrojov.

V Bratislava, apríl 2013

.....

Bc. Miloš Bella

## **Pod'akovanie**

Ďakujem vedúcemu mojej práce Mgr. Jánovi Mačutkovi, PhD. za vedenie, ochotu a čas, ktorý mi venoval pri písaní práce.

## Abstrakt

Bella Miloš: Miery dobrej zhody založené na štatistických vzdialenos-  
tiach: [Diplomová práca]. Univerzita Komenského v Bratislave. Fakulta ma-  
tematiky, fyziky a informatiky; Katedra aplikovanej matematiky a štatistiky;  
školiteľ: Mgr. Ján Mačutek, PhD. Bratislava 2013.

Motiváciou tejto práce sú problémy, ktoré sa vyskytujú pri použití chi-  
kvadrát testu dobrej zhody na testovanie dát v lingvistike. Tento test má  
dva základné nedostatky. V prípade veľkého počtu dát dáva tento test temer  
s istotou nulovú p-hodnotu. Druhým problémom tohto testu je požadovaná  
nezávislosť dát, čo je v lingvistike veľmi zriedkavé. Tento problém sa dá  
odstrániť použitím simulovaných p-hodnôt, ktoré nepožadujú nezávislosť dát.

Chi-kvadrát test dobrej zhody meria mieru podobnosti medzi modelom  
a dátami a patrí medzi štatistické vzdialenosťi. Cieľom tejto práce je pou-  
žitím simulovaných p-hodnôt na ligvistických dátach spočítať Hellingerovu  
vzdialenosť a totálnu variáciu a porovnať ich s chi-kvadrát vzdialenosťou.

**Kľúčové slová:** Chi-kvadrát dobrej zhody, štatistická vzdialenosť, dis-  
krétné rozdelenie, generovanie náhodných čísel.

## **Abstract**

Bella Miloš: Goodness-of-fit measures based on statistical distances: [Master thesis]. Comenius University in Bratislava. Faculty of mathematics, physics and informatics; Department of applied mathematics and statistics; supervisor: Mgr. Ján Mačutek, PhD. Bratislava 2013.

The motivation of this thesis are the problems of chi-square goodness-of-fit test when used on linguistics data. This test has two disadvantages. If the sample size is large the test rejects all null hypotheses. The stochastic independence of data, which is the requirement of this test, is problematic at linguistics. The solution is to evaluate the goodness-of-fit test by using simulated p-values, which does not require independence.

Chi-square goodness-of fit test belongs to statistical distances. The aim of this thesis is, by using simulated p-values, calculate Hellinger's distance, total variation and compare them to chi-square distance on linguistic's data.

**Key words:** Chi-square goodness-of-fit-test, statistical distance, discrete distribution, generation of random numbers.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>9</b>
<b>2</b>	<b>Teoretická časť</b>	<b>10</b>
2.1	Kolmogorovova definícia pravdepodobnosti . . . . .	10
2.2	Pravdepodobnostné rozdelenia . . . . .	11
2.3	Generovanie náhodných čísel z diskrétnych rozdelení . . . . .	12
2.4	Štatistické vzdialenosťi . . . . .	12
2.5	Pearsonov $\chi^2$ test dobrej zhody . . . . .	18
<b>3</b>	<b>Aplikácia štatistických vzdialenosťí na lingvistické dátá</b>	<b>19</b>
3.1	Všeobecná schéma postupu - simulované p-hodnoty . . . . .	19
3.2	Dáta od S.G. Čebanova . . . . .	19
3.2.1	Čebanovove výsledky . . . . .	19
3.2.2	Chyba u Čebanova . . . . .	21
3.2.3	Iné štatistické vzdialenosťi . . . . .	22
3.3	Dáta o dĺžke slov v dolnolužickej srbčine . . . . .	23
<b>4</b>	<b>Záver</b>	<b>28</b>
	<b>Literatúra</b>	<b>29</b>
	<b>Príloha</b>	<b>30</b>

# 1 Úvod

$\chi^2$  test dobrej zhody sa používa na meranie miery podobnosti medzi modelom a dátami. Ako bolo uvedené v článku [5], tento test má dve základné nevýhody. V prípade veľkého počtu dát dostaneme temer s istotou nulovú p-hodnotu. Test požaduje nezávislosť dát, čo je v prípade použitia na lingvistických dátach temer nesplniteľný predpoklad. Tento nedostatok možno obísť použitím simulovaných p-hodnôt.

V tejto práci pracujeme so štatistickými vzdialenosťami na dvoch typoch lingvistických dát. Pre tieto dátu bola v práci [2] vypočítaná  $\chi^2$  vzdialenosť. V prvom kroku počítame  $\chi^2$  vzdialenosť pre tieto dátu. Zhodu medzi modelom a dátami vyhodnocujeme použitím simulovaných p-hodnôt. Ďalej počítame Hellingerovu vzdialenosť a totálnu variáciu. Výstupom je porovnanie týchto troch vzdialenosťí a vyvodenie empirických záverov ohľadom potenciálnej nahrady  $\chi^2$  testu dobrej zhody inými štatistickými vzdialenosťami.

Pre naše postupy používame lingvistické dátá, pre ktoré bolo v práci [2] použitím softwaru Altmann Fitter návrhnuté predpokladané rozdelenie. Pre toto rozdelenie počítame v programe R optimalizovaný parameter (parametre) rozdelenia pre danú štatistickú vzdialenosť. Použitím tohto optimalizovaného parametra (parametrov) generujeme 2000 krát sadu náhodných čísel z predpokladaného rozdelenia. Pre každú vzdialenosť a text dostaneme hodnotu vzdialosti a simulovanú p-hodnotu.

Táto práca je rozdelená na dva hlavné celky. V prvej časti sú uvádzané teoretické poznatky, ktoré je potrebné ovládať na pochopenie neskôrnej aplikácie na dátach. Prvá časť je venovaná pojmom ako pravdepodobnostné rozdelenia,  $\chi^2$  test dobrej zhody a štatistické vzdialenosťi. Druhá časť je zameraná na prácu s dátami. Použitím troch štatistických vzdialenosťí a pomocou simulovaných p-hodnôt na lingvistických dátach dostaneme empirické závery ohľadom použiteľnosti resp. nepoužiteľnosti týchto vzdialenosťí ako nahrad Pearsonovho  $\chi^2$  testu dobrej zhody.

## 2 Teoretická časť

V tejto kapitole uvedieme základné poznatky z teórie pravdepodobnosti a o rozdeleniach pravdepodobnosti. Ako zdroj nám slúžila kniha [10].

### 2.1 Kolmogorovova definícia pravdepodobnosti

**Definícia 2.1.** Nech  $\Omega$  je ľubovoľná neprázdna množina. Neprázdný systém  $\mathcal{A}$  podmnožín množiny  $\Omega$  sa nazýva  $\sigma$ -algebra, ak platí

$$A \in \mathcal{A} \Rightarrow A^c \in \mathcal{A},$$

$$A_i \in \mathcal{A}, i = 1, 2, \dots \Rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{A}.$$

**Definícia 2.2** (Kolmogorov). Nech  $\Omega$  je neprázdna množina, nech  $\mathcal{A}$  je  $\sigma$ -algebra náhodných javov definovaných na  $\Omega$ . Pravdepodobnosťou sa nazýva reálna funkcia  $P(A)$  definovaná na  $\mathcal{A}$ , ktorá pre  $A \in \mathcal{A}, A_1, A_2, \dots \in \mathcal{A}, A_i \cap A_j = \emptyset$  a pre všetky  $i \neq j$ , splňa

$$P(\Omega) = 1,$$

$$P(A) \geq 0,$$

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i).$$

Najdôležitejšie vlastnosti takto zavedenej pravdepodobnosti uvedieme v nasledujúcej vete.

**Veta 2.1.** Ak  $A, B \in \mathcal{A}, A_1, \dots, A_k \in \mathcal{A}, A_i \cap A_j = \emptyset$  pre všetky  $i \neq j$ , tak platí

$$P(\emptyset) = 0,$$

$$0 \leq P(A) \leq 1,$$

$$P(A^c) = 1 - P(A)$$

$$P\left(\bigcup_{i=1}^k A_i\right) = \sum_{i=1}^k P(A_i),$$

$$A \subset B \Rightarrow P(A) \leq P(B),$$

$$A \subset B \Rightarrow P(B - A) = P(B) - P(A).$$

Trojicu  $(\Omega, \mathcal{A}, P)$  nazývame pravdepodobnostný priestor.

## 2.2 Pravdepodobnostné rozdelenia

**Definícia 2.3.** Nech  $X$  je reálna funkcia definovaná na  $\Omega$ , nech  $a, b$ , sú ľu bovolné reálne čísla, resp.  $-\infty, \infty$ . Zavedme užitočné označenie pre niektoré podmnožiny množiny  $\Omega$ :

$$[X < b] = \omega \in \Omega : X(\omega) < b,$$

$$[a < X < b] = \omega \in \Omega : a < X(\omega) < b.$$

**Definícia 2.4.** Majme pravdepodobnostný priestor  $(\Omega, \mathcal{A}, P)$ . Reálna funkcia  $X$  definovaná na  $\Omega$ , pre ktorú platí

$$x \in \mathbb{R} \Rightarrow [X < x] \in \mathcal{A}, \quad (1)$$

sa nazýva náhodná veličina.

Reálna funkcia  $X$  splňajúca (1) sa nazýva merateľná, prvky  $\sigma$ -algebry  $\mathcal{B}$  sa nazývajú merateľné množiny. Pre každú množinu  $B \in \mathcal{B}$  určuje náhodná veličina  $X$  pravdepodobnosť  $P_X(B)$  náhodného javu  $B$  pomocou vzťahu

$$P_X(B) = P(\omega \in \Omega : X(\omega) \in B) = P(X^{-1}(B)).$$

**Definícia 2.5.** Množinová funkcia

$$P_X(B) = P(X^{-1}(B)), \quad B \in \mathcal{B},$$

sa nazýva rozdelenie pravdepodobnosti náhodnej veličiny  $X$ .

**Definícia 2.6.** Nech  $X$  je náhodná veličina definovaná na pravdepodobnostnom priestore  $(\Omega, \mathcal{A}, P)$ . Reálna funkcia

$$F_X(x) = P[X < x]$$

sa nazýva distribučná funkcia náhodnej veličiny  $X$ .

**Definícia 2.7** (Diskrétne rozdelenie pravdepodobnosti). Nech existujú také  $x_1, x_2, \dots$ , pre ktoré platí:

$$\sum_{i=1}^{\infty} P[X = x_i] = 1.$$

Zoznam hodnôt, ktoré nadobúda náhodná veličina s diskrétnym rozdelením, a zoznam pravdepodobností, s ktorými tieto hodnoty náhodná veličina nadobúda, udávajú diskrétne rozdelenie pravdepodobnosti.

**Definícia 2.8** (Binomické rozdelenie). Budeme hovoriť, že náhodná premenná  $X$  má binomické rozdelenie pravdepodobnosti, ak nadobúda hodnoty  $j$  s pravdepodobnosťami

$$p_j = P(X = j) = \binom{n}{j} p^j q^{n-j}, \quad j = 0, 1, 2, \dots, n$$

kde  $p \in (0, 1)$  a  $q = 1 - p$ .

**Definícia 2.9** (Poissonovo rozdelenie). Hovoríme, že náhodná premenná  $X$  sleduje Poissonovo rozdelenie, ak nadobúda hodnoty  $j$  s pravdepodobnosťami

$$p_j = P(X = j) = \frac{\lambda^j e^{-\lambda}}{j!}, \quad j = 0, 1, 2, \dots,$$

kde  $\lambda > 0$  je parameter.

### 2.3 Generovanie náhodných čísel z diskrétnych rozdelení

V programoch, ktoré boli vytvorené pre naše účely, bolo potrebné generovať náhodné čísla z diskrétnych rozdelení. Pre tento účel bola použitá metóda z knihy [3] uvedená v ďalších riadkoch.

Uvažujme diskrétnu náhodnú premennú  $Y$  s hodnotami  $y_k$  a s odpovedajúcimi pravdepodobnosťami  $p_k$ ,  $k = 0, 1, \dots$ . Všeobecná metóda vychádza z toho, že ak náhodná premenná  $X$  má rovnomerné rozdelenie na intervale  $(0, 1)$ , potom pre  $0 \leq a < b \leq 1$  platí  $P(a \leq X < b) = b - a$ . To znamená, že

$$P\left(\sum_{j=0}^{m-1} p_j \leq X < \sum_{j=0}^m p_j\right) = p_m, \quad m = 0, 1, \dots$$

Náhodné číslo z daného rozdelenia získame teda tak, že generujeme náhodné číslo  $x$  z rovnomerného rozdelenia na intervale  $(0, 1)$  rozdelenia a hľadáme index  $m$ , pri ktorom platí

$$\sum_{j=0}^{m-1} p_j \leq x < \sum_{j=0}^m p_j$$

### 2.4 Štatistické vzdialenosťi

Jedným zo základných pojmov použitých v tejto práci sú štatistické vzdialenosťi. V nasledujúcich riadkoch uvádzame poznatky z knihy [7].

Najčastejšie používanými štatistickými vzdialenosťami sú  $f$ -divergencie. V súvislosti s  $f$ -divergenciou budeme pod  $f$  rozumieť ľubovoľnú pevnú konvexnú funkciu s definičným oborom  $(0, \infty)$  a s oblasťou hodnôt na rozšírenej reálnej priamke. Funkcia  $f$  je naviac striktne konvexná v bode  $u = 1$ . Ako vyplýva z dôsledku v prílohe, existuje práve jedno spojité rozšírenie  $f(0), f(\infty)$  tak, že rozšírená funkcia je konvexná na  $<0, \infty>$  a  $f(0) > -\infty$ . Bez narušenia všeobecnosti môžeme teda predpokladať, že  $f$  je definovaná a konvexná na  $<0, \infty>$ , striktne konvexná v  $u = 1$  a  $f(0) > -\infty$ .

**Veta 2.2.** *Existuje limita*

$$f(*) = \lim_{u \rightarrow \infty} \frac{f(u)}{u} \in \mathfrak{R},$$

*pričom platí*

$$-\infty < f(1) < f(0) + f(*). \quad (2)$$

*Ďalej platí*

$$\lim_{u \rightarrow 0+, v \rightarrow v_0} u f\left(\frac{v}{u}\right) = v_0 f(*), \quad (3)$$

$$\lim_{u \rightarrow 0+, v \rightarrow v_0} v f\left(\frac{u}{v}\right) = v_0 f(0), \quad (4)$$

*pre každé*  $v_0 \in (0, \infty)$ .

*Dôkaz.* Ak je funkcia  $f$  konvexná, je spojité na  $(0, \infty)$ , a teda  $f(1) \in \mathfrak{R}$ , t.j.  $f(1) > -\infty$ . Ďalej z vety (4.1 v Dodatku) dostaneme (najskôr pri  $(u', u, u'') = (0, 1, u)$  a potom pri  $(u', u, u'') = (1, u, u')$ ) nerovnosti

$$\frac{f(1) - f(0)}{1 - 0} < \frac{f(u) - f(1)}{u - 1} < \frac{f(u') - f(1)}{u' - 1}$$

pre všetky  $1 < u < u'$ . Z monotónnosti prostrednej funkcie na intervale  $u \in (1, \infty)$  vyplýva, že existuje

$$\lim_{u \rightarrow \infty} \frac{f(u) - f(1)}{u - 1} = \lim_{u \rightarrow \infty} \frac{f(u)}{u},$$

kde rovnosť vyplýva z konečnosti  $f(1)$ . Podľa ľavej nerovnosti platí aj (2). Keďže

$$\lim_{u \rightarrow 0+, v \rightarrow v_0} u f\left(\frac{v}{u}\right) = \lim_{u \rightarrow 0+, v \rightarrow v_0} v \frac{f\left(\frac{v}{u}\right)}{\frac{v}{u}},$$

vzťahy (3) a (4) vyplývajú zo spojitosti  $f$  na  $<0, \infty>$  a z toho, že limity  $f(*)$  a

$$f(0) = \lim_{u \rightarrow 0+} f(u)$$

existujú. □

**Dôsledok 2.1.** Ak je  $f(u)$  konvexná na  $(0, \infty)$ , tak

$$\bar{f}(u) = f(u) - f(1)$$

je dobre definovaná a konvexná na  $(0, \infty)$ , pričom  $\bar{f}(1) = 0$ . Ak je  $f(u)$  striktne konvexná v  $u = 1$ , je aj  $\bar{f}(u)$  striktne konvexná v  $u = 1$ , pričom  $\bar{f}(0) + \bar{f}(\infty) > 0$ .

Tento dôsledok nás oprávňuje predpokladať, že  $f(1) = 0$  bez narušenia všeobecnosti definície  $f$ -divergencie.

**Definícia 2.10.**  $f$ -divergenciu hustôt  $p, q$  (resp. príslušných pravdepodobností  $P, Q$ ) definujeme pre každú funkciu  $f(u)$ , konvexnú na  $(0, \infty)$  a striktne konvexnú v  $u = 1$ , výrazom

$$D_f(P||Q) = \sum_{x \in X} q(x) f\left(\frac{p(x)}{q(x)}\right), \quad (5)$$

kde predpokladáme, že  $f(1) = 0$  a kladieme

$$0f\left(\frac{0}{0}\right) = 0 \quad (6)$$

a

$$0f\left(\frac{p}{0}\right) = pf(\infty), \quad \forall p \in (0, \infty). \quad (7)$$

Všimnime si, že podmienka v (7) vyplýva z definície limity  $f(\infty)$  a z požiadavky spojitosťi

$$0f\left(\frac{p}{0}\right) = \lim_{\epsilon \rightarrow 0^+} \epsilon f\left(\frac{p}{\epsilon}\right).$$

Niektoré špeciálne prípady  $f$ -divergencie, prislúchajúce určitým konkrétnym konvexným funkciám  $f(u)$ , sa vo fyzike, matematickej analýze, pravdepodobnosti, štatistike i teórii informácie používajú už mnoho desaťročí. Nasledujúca veta má fundamentálny význam, lebo umožňuje chápať, v akom zmysle meria  $f$ -divergencia nepodobnosť pravdepodobnostných modelov. Poznamenajme, že za maximálne divergentné je prirodzené považovať také modely, v ktorých sú pravdepodobnosti  $P$  a  $Q$  ortogonálne. Znamená to, že existujú disjunktné podmnožiny  $E, F \subset X$ , pre ktoré platí  $P(E) = 1, Q(F) = 1$ .

**Veta 2.3.** Pre  $f$ -divergenciu platí nerovnosť

$$0 \leq D_f(P, Q) \leq f(0) + f(\infty),$$

pričom obidve rovnosti nemôžu nastať súčasne. Ľavá strana platí práve vtedy, keď  $P = Q$ , a pravá práve vtedy, keď  $P$  a  $Q$  sú ortogonálne.

Z tejto vety vyplýva, že modely  $(X, P)$  a  $(X, Q)$  sú navzájom podobné, ak ich  $f$ -divergencia  $D_f(P||Q)$  je blízka číslu 0. Maximálna podobnosť je vlastne zhoda pravdepodobností  $P$  a  $Q$  na príslušnej  $\sigma$ -algebре podmnožín množiny  $X$ . Naopak modely sú navzájom nepodobné, ak sa  $D_f(P||Q)$  blíži k svojej maximálnej možnej hodnote  $f(0) + f(*)$ . Maximálna nepodobnosť znamená, že v modeli  $(X, P)$  majú kladnú pravdepodobnosť iba tie javy, ktorých pravdepodobnosť je v modeli  $(X, Q)$  nulová, a naopak.

V nasledujúcej časti uvedieme prehľad najdôležitejších tried  $f$ -divergencií. Tie môžme rozdeliť na základe vytvárajúcich funkcií  $f(u)$ :

1.  $f(u) = u \log u$
2.  $f(u) = |u^\beta - 1|^{1/\beta}$
3.  $f(u) = |u - 1|^\alpha$
4.  $f(u) = \text{sign}(\alpha - 1)(u^\alpha - 1)$

1. Nech

$$f(u) = u \log(u),$$

Potom

$$I(P||Q) = \sum_{x \in X} q(x) \frac{p(x)}{q(x)} \log \frac{p(x)}{q(x)} = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)}.$$

Táto divergencia sa zvykne označovať ako  $I$ -divergencia.

2. Nech

$$f(u) = \frac{1}{2} |u^\beta - 1|^{1/\beta}.$$

Ak  $\beta \in (0, 1)$ , platí

$$\begin{aligned} D_\beta(P||Q) &= \frac{1}{2} \sum_{x \in X} q(x) \left( \left( \frac{p(x)}{q(x)} \right)^\beta - 1 \right) = \\ &= \frac{1}{2} \sum_{x \in X} q(x) \left( |p(x)^\beta - q(x)^\beta|^{\frac{1}{\beta}} \right) = \\ &= \frac{1}{2} \sum_{x \in X} q(x) - 2 \sqrt{p(x)q(x)} + p(x) = \end{aligned}$$

$$= 1 - \sum_{x \in X} \sqrt{p(x)q(x)}.$$

Táto divergencia sa označuje ako  $\beta$ -divergencia.

Špeciálnym prípadom  $\beta$ -divergencie je Hellingerova vzdialenosť, ktorú dostaneme, ak položíme  $\beta = \frac{1}{2}$ , teda pre

$$f(u) = \frac{1}{2}(1 - \sqrt{u})^2.$$

Dostaneme potom

$$\begin{aligned} D_{\frac{1}{2}}(P||Q) &= \frac{1}{2} \sum_{x \in X} q(x) \left( 1 - \sqrt{\frac{p(x)}{q(x)}} \right) = \\ &= \frac{1}{2} \sum_{x \in X} q(x) \left( 1 - 2\sqrt{\frac{p(x)}{q(x)}} + \frac{p(x)}{q(x)} \right) = \\ &= \frac{1}{2} \sum_{x \in X} q(x) - 2\sqrt{p(x)q(x)} + p(x) = \\ &= 1 - \sum_{x \in X} \sqrt{p(x)q(x)}. \end{aligned}$$

3. Nech

$$f(u) = |u - 1|^\alpha$$

Ak položíme  $\alpha = 1$ , dostaneme vzdialenosť, ktorá sa označuje ako totálna variácia. Je definovaná ako

$$\chi^1(P||Q) = V(P||Q) = \sum_{x \in X} q(x) \left| \frac{p(x)}{q(x)} - 1 \right| = \sum_{x \in X} |p(x) - q(x)|.$$

Ak položíme  $\alpha \in (1, \infty)$  dostaneme  $\chi^\alpha$ -divergenciu

$$\chi^\alpha(P||Q) = \sum_{x \in X} q(x) \left| \frac{p(x)}{q(x)} - 1 \right|^\alpha = \sum_{x \in X} \frac{|p(x) - q(x)|^\alpha}{q(x)^{\alpha-1}}.$$

$\chi^2$ -divergenciu

$$\chi^2(P||Q) = \sum_{x \in X} q(x) \left( \frac{p(x)}{q(x)} - 1 \right)^2 = \sum_{x \in X} \frac{(p(x) - q(x))^2}{q(x)}$$

získame dosadením  $\alpha = 2$ . Táto vzdialenosť sa používa pri  $\chi^2$  teste dobrej zhody.

4. Nech  $f(u) = \text{sign}(\alpha - 1)(u^\alpha - 1)$ . Ak  $\alpha \in (0, 1)$ , platí

$$D^\alpha(P||Q) = \sum_{x \in X} -q(x) \left( \left( \frac{p(x)}{q(x)} \right)^\alpha - 1 \right) = 1 - \sum_{x \in X} p(x)^\alpha q(x)^{1-\alpha}.$$

Pre  $\alpha \in (1, \infty)$  máme

$$D^\alpha(P||Q) = \sum_{x \in X} q(x) \left( \left( \frac{p(x)}{q(x)} \right)^\alpha - 1 \right) = \sum_{x \in X} \frac{p(x)^\alpha}{q(x)^{\alpha-1}} - 1.$$

Táto vzdialenosť sa označuje ako  $\alpha$ -divergencia.

O význame  $I$ -divergencie svedčí okrem iného aj to, že v priebehu mnohých desaťročí bola táto divergencia objavovaná a skúmaná s väčšou alebo menšou mierou nezávislosti veľkým počtom autorov. Konkrétnie mená autorov tu neuvádzame, niektoré možno nájsť v knihe [7].

$V(P||Q)$  je v teórii pravdepodobnosti používaná už dlho pod názvom totálna variácia, v matematickej štatistike je známa ako Kolmogorovova vzdialenosť.

V nasledujúcej vete bez dôkazu uvedieme známe vzťahy medzi divergenciami, ktoré sú dôležité pre pochopenie ich topologických vlastností.

**Veta 2.4.** Pre všetky pravdepodobnosti  $P, Q$  na množine  $X$  platí:

1.  $D_1(P||Q) = \chi^1(P||Q) = V(P||Q),$
2.  $D_{\frac{1}{2}}(P||Q) = 2D^{\frac{1}{2}}(P||Q),$
3.  $\chi^2(P||Q) = D^2(P||Q),$
4.  $V(P||Q) < (\chi^\alpha(P||Q))^{\frac{1}{\alpha}} \quad \forall \alpha \geq 1,$
5.  $\left[ \left( 1 - \frac{V(P||Q)}{2} \right)^\beta - \left( 1 - \frac{V(P||Q)}{2} \right)^\beta \right]^{\frac{1}{\beta}} \leq D_\beta(P||Q) \leq V(P||Q)$   
pre  $0 < \beta \leq 1$ ,
6.  $1 - \left( 1 + \frac{V(P||Q)}{2} \right)^{\max(\alpha, 1-\alpha)} \left( 1 - \frac{V(P||Q)}{2} \right)^{\min(\alpha, 1-\alpha)} \leq D^\alpha(P||Q) \leq \frac{V(P||Q)}{2}$   
pre  $0 < \alpha < 1$ .

Ďalej platí, že  $D^{\frac{1}{2}}(P||Q)$  a  $\chi^1(P||Q) = V(P||Q)$  a taktiež  $D_\beta(P||Q)^\beta$  pri ľubovoľnej  $\beta$  sú metriky na priestore všetkých pravdepodobností množiny  $X$ .

## 2.5 Pearsonov $\chi^2$ test dobrej zhody

Nulová hypotéza Pearsonovho  $\chi^2$  testu dobrej zhody je, že pozorovania pochádzajú z konkrétneho teoretického rozdelenia pravdepodobnosti. Testovacia štatistika je definovaná ako

$$\chi^2 = \sum_{i=1}^n \frac{(f_i - NP_i)^2}{NP_i}, \quad (8)$$

kde  $f_i$  je sledovaná empirická početnosť hodnôt v  $i$ -tej triede,  $P_i$  teoretická pravdepodobnosť hodnôt v  $i$ -tej triede,  $n$  je počet tried, do ktorých sú dátia rozdelené, a  $N$  je veľkosť pozorovanej vzorky (celkový počet pozorovaní). Ak platí nulová hypotéza, štatistika (8) asymptoticky sleduje  $\chi^2$  rozdelenie s  $n - p - 1$  stupňami voľnosti ( $n$  je počet tried,  $p$  je počet odhadovaných parametrov). Očakávané početnosti by nemali byť príliš malé, Snedecor a Cochran [6] navrhovali, aby žiadna z početností nebola menšia ako 1. Triedy s očakávanými početnosťami menšími ako 1 majú byť zlúčené. Test (8) je matematicky korektný, ale podobne ako ostatné štatistické testy zamieta všetky nulové hypotézy, ak je vzorka príliš veľká. Toto je často prípad v lingvistike, kde vzorky o veľkosti desiatok tisíc a viac nie sú výnimkou. Pre takéto obrovské sady dát je tento test prakticky nepoužiteľný. Tento nedostatok do istej miery odstraňuje koeficient diskrepancie. Predpokladajúc, že  $\chi^2$  štatistika rastie lineárne s veľkosťou vzorky, ak sú teoretické a empirické relatívne početnosti fixné, koeficient diskrepancie (pozri [1]) je definovaný ako

$$C = \frac{\chi^2}{N}. \quad (9)$$

Za prijateľné sú podľa [5] považované hodnoty koeficientu  $C \leq 0.02$ , prípadne hodnoty  $C \leq 0.05$ . Test (8) je v lingvistike používaný na testovanie, ak je vzorka "primerane" veľká. Naopak koeficient diskrepancie je pre  $\chi^2$  test vhodný, ak je testovacia vzorka príliš veľká. Oveľa závažnejším problémom ako veľkosť vzorky je splnenie predpokladov testu (8). Jedným zo základných predpokladov Pearsonovho  $\chi^2$  testu dobrej zhody je, že pozorovania pochádzajú z náhodného výberu, čo je postupnosť nezávislých a rovnako rozdelených náhodných premenných. Predpokladanie nezávislosti by napríklad znamenalo, že ak jazyk používa grafému  $a$ , ľubovoľne dlhá postupnosť pozostávajúca iba z grafémy  $a$  by bola možná, jej výskyt by mal závisieť iba na dĺžke postupnosti a na očakávanej početnosti grafémy  $a$  v jazyku. Keďže  $a$  je jedna z najčastejšie používaných grafém, za predpokladu nezávislosti by sa slovo *aaaaaa* malo vyskytovať v textoch častejšie ako ostatné zmysluplné slová, ktoré obsahujú menej používané grafémy.

### **3 Aplikácia štatistických vzdialenosí na lingvistické dátá**

#### **3.1 Všeobecná schéma postupu - simulované p-hodnoty**

Hlavnou náplňou tejto práce je výpočet troch druhov štatistických vzdialenosí na vopred určené dátá. Na dátach, ktoré používame pre naše účely, bola v práci [2] spočítaná  $\chi^2$  vzdialenosť, čo je vlastne test dobrej zhody. Našim cieľom bolo okrem spomínaného  $\chi^2$  testu dobrej zhody spočítať Hellingerovu vzdialenosť a totálnu variáciu.

Pre naše účely sme v tejto diplomovej práci použili dva typy dát, na ktoré sme aplikovali naše postupy. V tomto odseku uvedieme všeobecnú schému postupu.

Východzím bodom je, že máme k dispozícii predpokladané rozdelenie dát. Potom postupujeme nasledovne:

1. Optimalizácia parametrov rozdelenia pre danú štatistickú vzdialenosť a pre dané dátá. Výsledkom je teda optimalizovaná hodnota parametra (parametrov), pre ktorú (ktoré) je daná vzdialenosť minimálna.
2. 2000 krát generujeme náhodné čísla z rozdelenia s optimalizovaným parametrom (parametrami), pričom počet náhodných čísel je zhodný s počtom dát v súbore. (Počet 2000 opakovaní bol zvolený preto, lebo program R bežne vykonáva 2000 opakovaní pri výpočte simulovaných p-hodnôt.)
3. Pre každý vygenerovaný súbor vypočítame vzdialenosť od predpokladaného rozdelenia s optimalizovaným parametrom.
4. Spočítame simulovanú p-hodnotu (teda počet tých vygenerovaných súborov, v ktorých je vzdialenosť väčšia ako v prípade optimalizovaného parametra, vydelený počtom všetkých generovaní).

#### **3.2 Dátá od S.G. Čebanova**

##### **3.2.1 Čebanovove výsledky**

V tejto podkapitole popíšeme postup, ktorý bol použitý v článku [2]. Tento postup uvádzame preto, lebo je v ňom závažná chyba urobená pri výpočte. Tieto lingvistické dátá a výpočty pochádzajú od ruského lekára Sergeja Grigorjeviča Čebanova (1897-1966). Jeho záujem o lingvistiku sa zameriaval hlavne na vývoj jazyka. Čebanov považoval "distribúciu slov podľa počtu

slabík" za jednu z najdôležitejších štatistických charakteristik štruktúry jazyka. Čebanov skúmal 127 rôznych jazykov a dialektov po dobu viac ako 20 rokov.

Čebanov hľadal všeobecný model pre rozdelenie slov podľa počtu slabík. Čebanovov počiatočný predpoklad bol špecifický vzťah medzi strednou hodnotou počtu slabík v texte  $\bar{x}$  a relatívnymi frekvenciami  $p_i$  jednotlivých tried podľa počtu slabík. Poznajúc strednú hodnotu rozdelenia, Čebanov predpokladal, že Poissonovo rozdelenie je adekvátnym modelom pre jeho dátu.

Poissonovo rozdelenie je definované ako

$$P_x = \frac{e^{-a} a^x}{x!} \quad x = 0, 1, 2, \dots \quad (10)$$

Kedže rovnica (10) je platná pre  $x = 0, 1, 2, \dots$  a  $a \geq 0$  a keďže sa v teste nenachádzajú žiadne nulovo-slabičné slová, tak je pre model vhodnejšie použiť posunuté Poissonovo rozdelenie

$$P_x = \frac{e^{-a} a^{x-1}}{(x-1)!} \quad x = 1, 2, 3, \dots \quad (11)$$

V knihe [2] boli uvedené a použité 3 z Čebanovových dátových súborov, ktoré budú rovnako použité i pre naše účely. Jedná sa o nemecký text *Parzival*, starosaský text *Heliand* a tretí text je urývok z knihy od Leva N. Tolstoja *Vojna i mir*. Absolútne frekvencie ( $f_i$ ) a zodpovedajúce relatívne frekvencie  $p_i$  sú uvedené v tabuľke. Počet slabík v slove označuje premennú  $i$ . Dáta predstavujeme v Tabuľke 1.

$i$	Parzival		Heliand		Vojna i mir	
	$f_i$	$p_i$	$f_i$	$p_i$	$f_i$	$p_i$
1	1823	0.628	1572	0.469	466	0.283
2	849	0.292	1229	0.367	541	0.328
3	194	0.067	452	0.135	391	0.237
4	37	0.013	83	0.025	172	0.104
5			14	0.004	64	0.039
6					15	0.009
$\sum$	2903		3350		1698	

**Tabuľka 1:** Relatívne a absolútne početnosti  $i$ -slabičných slov

Čebanov počítal  $\chi^2$  test dobrej zhody na daných dátach. Pre prvé dátu *Parzival*, s počtom tried  $k = 4$  dostal  $\chi^2 = 1.45$ . Táto hodnota sa môže považovať za dobrý fit, nakoľko  $p(\chi^2) = 0.48$  pre dva stupne voľnosti. Z dát *Heliand* Čebanov nedostal dobré výsledky. Hodnota  $\chi^2 = 10.35$  je aj napriek

horšiemu výsledku stále akceptovateľná na hladine významnosti  $\alpha = 0.01$  ( $p(\chi^2) = 0.016$  pre tri stupne voľnosti). Rovnako pre dátá *Vojna i mir* vyšli Čebanovovi dobré výsledky,  $\chi^2 = 5.82$  ( $p(\chi^2) = 0.213$  pre štyri stupne voľnosti).

### 3.2.2 Chyba u Čebanova

Dôležitou chybou u Čebanova pri počítaní  $\chi^2$  štatistiky bolo, že všetky teoretické pravdepodobnosti počítal podľa vzorca

$$P_x = \frac{e^{-\bar{a}} \bar{a}^x}{x!}, \quad x = 1, 2, \dots, k, \quad (12)$$

kde  $k$  je maximálna dĺžka slova v analyzovanom teste. To nespĺňa základnú podmienku

$$\sum_{x=1}^k P_x = 1.$$

Tento nedostatok sa ľahko dá napraviť tým, že teoretické pravdepodobnosti počítame pomocou vzorca (12) pre  $x = 1, 2, \dots, k - 1$  a

$$P_k = 1 - \sum_{x=1}^{k-1} P_x. \quad (13)$$

V našom postupe sme teda počítali pravdepodobnosti podľa vzora (12) doplneného podľa vzorca (13). Ako druhý krok sme hľadali optimalizovaný parameter  $\bar{a}$ . Tento postup sme robili v programe *R*. Všetky programy možno nájsť v prílohe. Po optimalizácii parametra  $\bar{a}$  sme dostali nasledovné teoretické frekvencie a  $\chi^2$  štatistiky.

$i$	Parzival		Heliand		Vojna i mir	
	$f_i$	$Np_i$	$f_i$	$Np_i$	$f_i$	$Np_i$
1	1823	1821.58	1572	1611.48	466	440.78
2	849	848.93	1229	1179.29	541	581.56
3	194	197.82	452	431.51	391	383.65
4	37	34.67	83	105.26	172	168.72
5			14	22.46	64	55.65
6					15	18.64
$\sum$	2903		3350		1698	
$\chi^2$	0.23		11.93		6.44	

**Tabuľka 2:** Početnosti  $i$ -slabičných slov a  $\chi^2$  štatistika

V Tabuľke 3 môžeme vidieť porovnanie našich  $\chi^2$  štatistik s prislúchajúcimi simulovanými p-hodnotami a výsledky od Čebanova.

	Parzival		Heliand		Vojna i Mir	
Čebanov	$\chi^2$	p-hodnota	$\chi^2$	p-hodnota	$\chi^2$	p-hodnota
	1.45	0.48	10.35	0.016	5.82	0.213
Naše výsledky	$\chi^2$	p-hodnota	$\chi^2$	p-hodnota	$\chi^2$	p-hodnota
	0.23	0.971	11.93	0.0185	6.44	0.2655

**Tabuľka 3:** Porovnanie výsledkov  $\chi^2$  štatistiky

Možno si všimnúť, že naše  $\chi^2$  štatistiky nadobúdajú iné hodnoty ako v prípade výsledkov od Čebanova. Tento rozdiel je spôsobený jeho iným (nesprávnym) postupom.

### 3.2.3 Iné štatistické vzdialenosťi

V tejto práci venujeme pozornosť nie len  $\chi^2$  vzdialenosťi (v ďalšom  $\chi^2$ ), ale aj ostatným štatistickým vzdialenosťiam, a to Hellingerovej vzdialenosťi (v ďalšom HV) a totálnej variácii (v ďalšom TV). Rovnako i pri týchto vzdialenosťach sme optimalizovali parameter  $\hat{a}$  a následne sme spočítali dané vzdialenosťi. Výsledky môžeme vidieť v nasledujúcej tabuľke.

	Parzival	Heliand	Vojna i mir
$\chi^2$	0.231	11.929	6.439
$\hat{a}$	0.466	0.732	1.3194
P-value	0.971	0.019	0.267
<i>HV</i>	0.003	0.022	0.022
$\hat{a}$	0.466	0.727	1.318
P-value	0.976	0.011	0.247
<i>TV</i>	0.001	0.012	0.026
$\hat{a}$	0.465	0.757	1.333
P-value	0.999	0.318	0.176

**Tabuľka 4:** Štatistické vzdialenosťi a ich simulované p-hodnoty

Možno si všimnúť, že v prvých dvoch textoch sme najlepšiu simulovanú p-hodnotu dostali v prípade totálnej variácie. Podobný jav sledujeme aj v prípade dát o dĺžke slov v dolnolužickej srbčine v ďalšej kapitole.

### 3.3 Dáta o dĺžke slov v dolnolužickej srbčine

Ako ďalšie dátu sme použili dĺžky slov v žurnalistických textoch v dolnolužickej srbčine. Dátu sme prebrali z práce [8]. Dolnolužickou srbčinou hovorí asi 20000 ľudí v nemeckom spolkovom štáte Brandenburg.

Dátu použité v tejto časti práce majú dĺžku 100-1000 slov. Štúdie boli vykonané na homogénnych textoch a ide o články z dolnosrbského časopisu Nowy Casnik. Pre každý analyzovaný text bol spočítaný počet slov spadajúcich do príslušnej skupiny podľa počtu slabík. Testovali sme zhodu dát s hyper-Poissonovým rozdelením. Hyper-Poissonovo rozdelenie (pozri [9]) je definované ako

$$P_x = \frac{a^{x-1}}{b^{(x-1)} {}_1F_1(1; b; a)}, \quad x = 1, 2, \dots \quad (14)$$

kde  ${}_1F_1(1; b; a)$  je hypergeometrická funkcia s parametrami  $a$  a  $b$ .

Hypergeometrická funkcia je definovaná v [9] ako

$${}_1F_1(1; b; a) = 1 + \frac{b}{(a)1!} + \frac{b(b+1)}{a(a+1)2!} + \dots$$

Rovnako i pri týchto dátach sme počítali s tromi štatistickými vzdialenosťami:  $\chi^2$  vzdialenosťou, Hellingerovou vzdialenosťou a totálnej variáciou. Pre každý z desiatich textov je vypočítaná optimalizovaná štatistika spolu s optimalizovanými parametrami daného rozdelenia a simulovaná p-hodnota. V nasledujúcej časti sú pre lepší prehľad uvedené iba výsledky. Podrobnejšie informácie spolu s konkrétnymi dátami sú uvedené v Prílohe.

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	10.695	1.155	1.167	0.029
TV	0.061	0.723	0.658	0.260
HV	0.902	1.012	1.054	0.069

**Tabuľka 5:** Text 1

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	8.061	1.396	1.618	0.210
TV	0.036	0.689	0.644	0.675
HV	0.062	0.991	1.064	0.455

**Tabuľka 6:** Text 2

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	1.601	1.851	2.449	0.904
TV	0.028	1.430	1.801	0.891
HV	0.035	1.820	2.424	0.896

**Tabuľka 7:** Text 3

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	6.602	1.985	2.005	0.170
TV	0.0458	2.740	3.132	0.656
HV	0.069	1.772	1.792	0.184

**Tabuľka 8:** Text 4

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	20.775	3.645	4.294	0.010
TV	0.112	4.667	6.647	0.050
HV	0.128	3.474	4.423	0.020

**Tabuľka 9:** Text 5

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	8.765	2.793	3.904	0.066
TV	0.053	3.796	5.867	0.523
HV	0.081	2.251	3.210	0.113

**Tabuľka 10:** Text 6

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	2.381	0.945	1.065	0.671
TV	0.027	1.156	1.391	0.848
HV	0.041	0.906	1.027	0.633

**Tabuľka 11:** Text 7

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	8.321	0.808	0.736	0.079
TV	0.053	0.514	0.424	0.469
HV	0.086	0.706	0.665	0.168

**Tabuľka 12:** Text 8

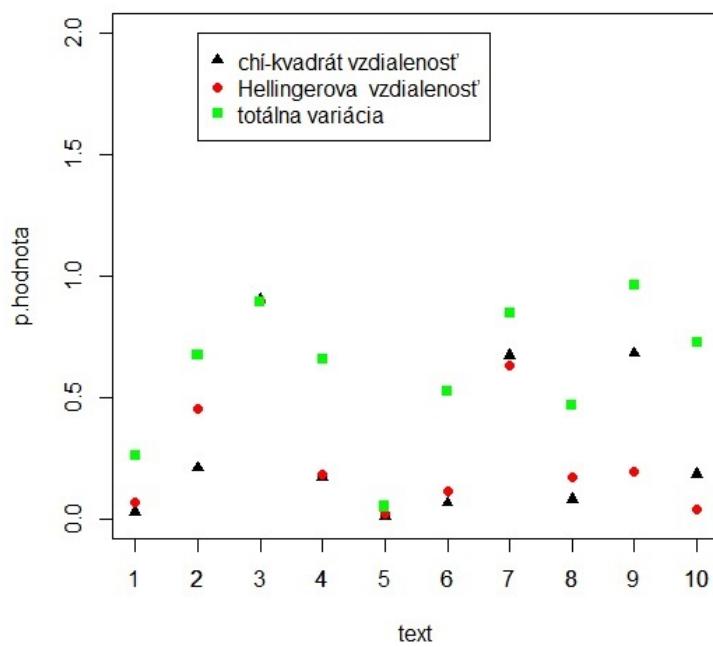
Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	3.101	1.109	1.216	0.680
TV	0.023	1.260	1.455	0.963
HV	0.085	0.814	0.845	0.195

**Tabuľka 13:** Text 9

Vzdialenosť	Štatistika	a	b	P-hodnota
$\chi^2$	6.199	1.355	1.459	0.183
TV	0.044	1.098	1.197	0.728
HV	0.109	0.808	0.829	0.040

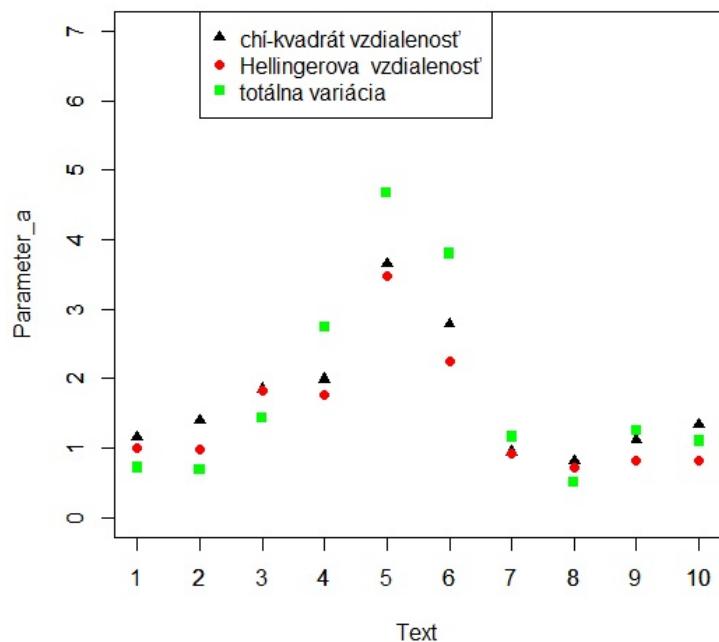
**Tabuľka 14:** Text 10

Pre ľahšiu orientáciu vo výsledkoch sme vyrobili grafy znázorňujúce porovnanie simulovaných p-hodnôt a optimalizovaných parametrov pre jednotlivé vzdialenosťi.

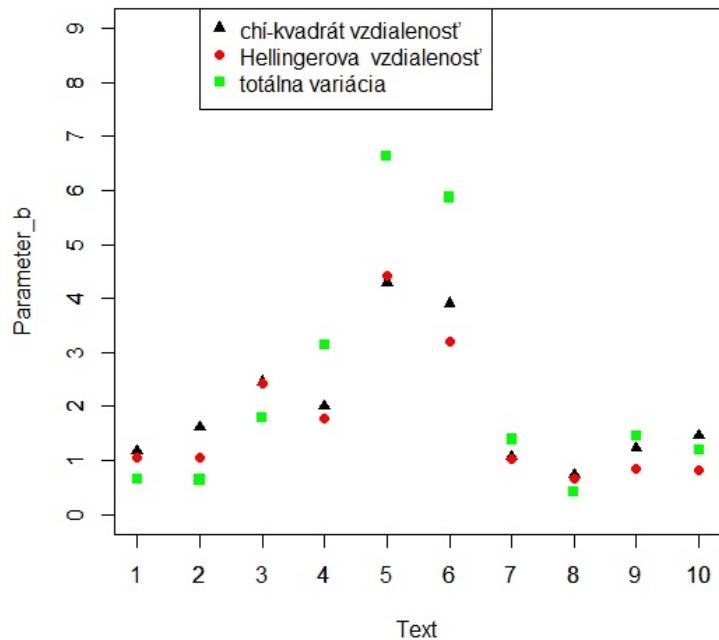


Obr. 1: Porovnanie simulovaných p-hodnôt

Z uvedených výsledkov a rovnako i z grafu je možné si všimnúť, že skoro vo všetkých desiatich textoch je simulovaná p-hodnota v prípade použitia  $\chi^2$  vzdialenosť a Hellingerovej vzdialenosť dosť podobná. Naopak v prípade totálnej variácie sú p-hodnoty oveľa vyššie. Podobný jav sme zaznamenali aj v dvoch z troch analyzovaných textoch od Čebanova [pozri Kapitolu 3.2]. Zdá sa, že Hellingerova vzdialenosť dáva podobné výsledky ako  $\chi^2$  test dobrej zhody a preto by Hellingerova vzdialenosť mohla byť použitá ako istá obmena práve spomenutého testu dobrej zhody. Čo sa skrýva za vyššími hodnotami p-hodnôt v prípade totálnej variácie nie je úplne zrejmé. Možno si všimnúť, že v prípade totálnej variácie nastáva optimalizácia parametrov  $a$  a  $b$  tak, že teoretické frekvencie dvoch hodnôt sa vždy rovnajú tým reálnym. Nie je teda zrejmé, či totálna variácia je nevhodná ako alternatíva testu dobrej zhody vďaka nízkej ochote zamieňať výsledky, alebo skutočne dosahuje táto vzdialenosť lepšie optimalizované hodnoty.



Obr. 2: Porovnanie hodnôt optimalizovaného parametra a



Obr. 3: Porovnanie hodnôt optimalizovaného parametra b

Rovnaký empirický záver možno vyvodiť i v prípade optimalizovaných parametrov  $a$  a  $b$ . Optimalizované parametre v prípade  $\chi^2$  vzdialenosť dosahujú podobné hodnoty ako v prípade Hellingerovej vzdialenosť. Zdá sa, že parametre totálnej variácie nadobúdajú iné hodnoty. Samotné hodnoty týchto parametrov nám nehovoria nič z čisto matematického hľadiska, no z pohľadu lingvistiky môžu mať význam pri interpretácii jednotlivých štatistických vzdialenosťí.

## 4 Záver

Táto práca sa zaobera porovnávaním  $\chi^2$  testu dobrej zhody, Hellingerovej vzdialenosťi a totálnej variácie na lingvistických dátach.

Prvým hlavným výsledkom bolo nájdenie chyby pri počítaní v práci [2] na dátach od Čebanova. Pri počítaní  $\chi^2$  vzdialenosťi sú dáta rozdelené do viacerých tried. Pre každú triedu je podľa predpokladaného rozdelenia vypočítaná očakávaná frekvencia  $p_i$ . V prípade použitia posunutého Poissonovho rozdelenia je potrebné pre poslednú triedu dát vypočítať očakávanú frekvenčiu ako  $1 - \sum(p_i)$ . Chybou, ktorej sa dopustili v knihe [2], je, že aj posledná trieda bola počítaná podľa vzorca pre predpokladané rozdelenie, čo viedlo k problému, že súčet očakávaných pravdepodobností nie je rovný 1.

Druhým výstupom je vypočítanie týchto troch vzdialenosťí na dvoch typoch dát. V prvom prípade máme tri menšie sady dát. Keďže sa jedná o dáta z troch rôznych jazykov, nie je možné jednoznačne vyvodzovať výsledky o týchto vzdialostiach. No i v tomto prípade je možné si všimnúť, že p-hodnoty pre totálnu variáciu nadobúdajú v dvoch z troch prípadov oveľa väčšie hodnoty ako pre ďalšie dve použité štatistiky.

V druhej sade dát, ktorá obsahuje dáta z 10 rôznych textov z dolnolužickej srbčiny, je možné si všimnúť, že temer v každom teste nadobúda totálna variácia vyššie simulované p-hodnoty ako Hellingerova vzdialenosť a  $\chi^2$  vzdialenosť. Naopak Hellingerova vzdialenosť dosahuje podobné hodnoty optimalizovaných parametrov a simulovaných p-hodnôt ako  $\chi^2$  vzdialenosť.

## Literatúra

- [1] Cressie, N., Read, T.R.C. (1984). Multinomial goodness-of-fit tests. *Journal of the Royal Statistical Society. Series B (Methodological)*, 46(3), 440-464.
- [2] Grzybek, P. (2006). History and methodology of word length studies. In: Contributions to the Science of Text and Language. Word Length Studies and Related Issues (Grzybek, P., ed.), pp. 15-90. Dordrecht: Springer.
- [3] Kalas J., Pekár J. (1991). Simulačné metódy. Bratislava: Polygrafické stredisko UK.
- [4] Lamoš F. (1983). Základy teórie pravdepodobnosti. Bratislava: Polygrafické stredisko UK.
- [5] Mačutek J., Wimmer G. (2013). Evaluating goodness-of-fit of discrete distribution models in quantitative linguistics. *Journal of Quantitative Linguistics* (to appear).
- [6] Snedecor, G.W., Cochran, W.G. (1989). Statistical Methods (8th ed.). Ames (IA): Iowa State University Press.
- [7] Vajda I. (1982). Teória informácie a štatistického rozhodovania. Bratislava: vydavateľstvo Alfa.
- [8] Wilson, A.. (2006). Word-length distribution in present-day Lower Sorbian newspaper texts. In: Contributions to the Science of Text and Language. Word Length Studies and Related Issues (Grzybek, P., ed.), pp. 319-327. Dordrecht: Springer.
- [9] Wimmer, G., Altmann, G. (1999). Thesaurus of univariate discrete probability distributions. Essen: Stamm.
- [10] Zvára K., Štěpán J. (2001). Pravděpodobnost a matematická statistika. Praha: Matfyzpress - Vydatelství Matematicko-fyzikální Univerzity Karlovy.

## Príloha

**Veta 4.1** (I-interval). Ak  $f : I(a, b) \rightarrow \mathbb{R}$  je konvexná a  $u' < u < u''$  sú ľubovoľné tri body z  $I(a, b)$ , tak

$$\frac{f(u) - f(u')}{u - u'} \leq \frac{f(u'') - f(u')}{u'' - u'} \leq \frac{f(u'') - f(u)}{u'' - u}$$

pričom nerovnosti sú ostré, ak je  $f$  striktne konvexná v bode  $u$ .

**Dôsledok 4.1.** Ak je  $f : (a, b) \rightarrow R$  konvexná, tak existujú v  $\mathbb{R}$  limity

$$f(a) = \lim_{u \rightarrow a^+} f(u), \quad f(b) = \lim_{u \rightarrow b^-} f(u)$$

pričom takto (jednoznačne) rozšírená funkcia  $f : < a, b > \rightarrow R$  je konvexná. Rozšírená funkcia je striktne konvexná (v bode  $u_0 \in (a, b)$ ) práve vtedy, keď  $f$  je striktne konvexná (v bode  $u_0$ ).

### Podrobnejšie výsledky z dolnolužickej srbčiny

Nasledujúce tabuľky obsahujú výsledky z 10 textov, kde:

- $x_i$  je počet slabík v slove
- $f_i$  je sledovaná frekvencia i-slabičných slov
- $NP_i$  je teoretická frekvencia i-slabičných slov
- $a$  je optimalizovaný parameter pre danú štatistiku
- $b$  je optimalizovaný parameter pre danú štatistiku
- $\chi^2$  optimalizovaná chi-kvadrát štatistika
- $VV$  optimalizovaná totálna variácia
- $HV$  optimalizovaná Hellingerova vzdialenosť
- $P_{value}$  p-hodnota pre danú vzdialenosť

Text 1			Text 2		
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	61	61.10	1	71	73.51
2	67	59.51	2	76	63.43
3	19	31.72	3	25	33.82
4	18	11.58	4	13	13.05
5	2	4.09	5	2	3.94
			6	1	0.98
			7	1	0.25
$\chi^2$	10.69457		$\chi^2$	8.06078	
$a$	1.15527		$a$	1.39572	
$b$	1.16686		$b$	1.61750	
$P_{value}$	0.0285		$P_{value}$	0.2095	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	61	63.29	1	71	73.40
2	67	60.77	2	76	68.64
3	19	29.95	3	25	33.03
4	18	9.93	4	13	10.70
5	2	3.07	5	2	2.61
			6	1	0.51
			7	1	0.10
$HV$	0.90243		$HV$	0.06242	
$a$	1.01238		$a$	0.99161	
$b$	1.05441		$b$	1.06371	
$P_{value}$	0.0685		$P_{value}$	0.4545	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	61	61.00	1	71	71.00
2	67	67.00	2	76	76.00
3	19	29.21	3	25	31.86
4	18	7.94	4	13	8.30
5	2	1.85	5	2	1.57
			6	1	0.23
			7	1	0.03
$TV$	0.06113		$TV$	0.03629	
$a$	0.72286		$a$	0.68909	
$b$	0.6581		$b$	0.64375	
$P_{value}$	0.2595		$P_{value}$	0.675	

Text 3			Text 4		
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	68	68.07	1	56	52.93
2	54	51.45	2	49	52.40
3	23	27.61	3	32	34.61
4	14	11.49	4	25	17.16
5	4	3.90	5	5	9.89
6	1	1.47			
$\chi^2$	1.60087		$\chi^2$	6.60175	
$a$	1.85100		$a$	1.98527	
$b$	2.44900		$b$	2.00530	
$P_{value}$	0.904		$P_{value}$	0.1695	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	68	68.64	1	56	54.53
2	54	51.53	2	49	53.93
3	23	27.39	3	32	34.22
4	14	11.27	4	25	15.99
5	4	3.78	5	5	8.33
6	1	1.40			
$HV$	0.03524		$HV$	0.06897	
$a$	1.82010		$a$	1.77167	
$b$	2.42433		$b$	1.79159	
$P_{value}$	0.8955		$P_{value}$	0.184	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	68	68.00	1	56	56.00
2	54	54.00	2	49	49.00
3	23	27.57	3	32	32.50
4	14	10.37	4	25	17.35
5	4	3.09	5	5	12.15
$TV$	0.02789316		$TV$	0.04578	
$a$	1.43047		$a$	2.74032	
$b$	1.80133		$b$	3.13179	
$P_{value}$	0.891		$P_{value}$	0.656	

Text 5			Text 6		
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	56	46.74	1	68	64.11
2	28	39.68	2	44	45.87
3	24	27.32	3	21	26.13
4	29	15.82	4	20	12.36
5	6	13.45	5	3	7.53
$\chi^2$	20.77491		$\chi^2$	8.76540	
$a$	3.64527		$a$	2.79295	
$b$	4.29435		$b$	3.90350	
$P_{value}$	0.01		$P_{value}$	0.066	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	56	51.63	1	68	67.20
2	28	40.56	2	44	47.12
3	24	25.99	3	24	25.19
4	29	14.06	4	20	10.88
5	6	10.77	5	3	5.62
$HV$	0.12760		$HV$	0.08066	
$a$	3.47404		$a$	2.25054	
$b$	4.42250		$b$	3.20969	
$P_{value}$	0.02		$P_{value}$	0.1125	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	56	56.00	1	68	68.00
2	28	39.32	2	44	44.00
3	24	24.00	3	21	24.32
4	29	12.95	4	20	11.74
5	6	10.72	5	3	7.94
$TV$	0.11221		$TV$	0.05296	
$a$	4.66746		$a$	3.79623	
$b$	6.64717		$b$	5.86690	
$P_{value}$	0.0495		$P_{value}$	0.5225	

Text 7			Text 8		
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	77	75.83	1	51	50.39
2	64	67.24	2	62	55.31
3	36	30.76	3	15	25.74
4	6	9.48	4	12	7.60
5	3	2.69	5	1	1.97
$\chi^2$	2.38132		$\chi^2$	8.32148	
$a$	0.94481		$a$	0.80789	
$b$	1.06548		$b$	0.73607	
$P_{value}$	0.671		$P_{value}$	0.079	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	77	76.64	1	51	52.71
2	64	67.62	2	62	56.79
3	36	30.22	3	15	23.87
4	6	9.05	4	12	6.24
5	3	2.47	5	1	1.38
$HV$	0.04149		$HV$	0.08600	
$a$	0.90599		$a$	0.70603	
$b$	1.02681		$b$	0.66541	
$P_{value}$	0.633		$P_{value}$	0.168	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	77	77.00	1	51	51.00
2	64	64.00	2	62	62.00
3	36	30.95	3	15	22.43
4	6	10.55	4	12	4.76
5	3	3.50	5	1	0.81
$TV$	0.02716		$TV$	0.05267	
$a$	1.15618		$a$	0.51493	
$b$	1.39103		$b$	0.42357	
$P_{value}$	0.8475		$P_{value}$	0.469	

Text 9			Text 10		
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	60	58.94	1	48	46.65
2	52	53.78	2	44	42.37
3	30	26.92	3	19	22.84
4	9	9.29	4	13	8.75
5	0	2.44	5	0	3.39
6	1	0.63			
$\chi^2$	3.10105		$\chi^2$	6.19936	
$a$	1.10921		$a$	1.32520	
$b$	1.21554		$b$	1.45910	
$P_{value}$	0.6795		$P_{value}$	0.1825	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	60	59.79	1	48	48.41
2	52	57.64	2	44	47.23
3	30	25.45	3	19	20.88
4	9	7.28	4	13	5.97
5	0	1.54	5	0	1.50
6	1	0.3			
$HV$	0.08450		$HV$	0.10922	
$a$	0.81439		$a$	0.80848	
$b$	0.84471		$b$	0.82867	
$P_{value}$	0.1945		$P_{value}$	0.0395	
$x_i$	$f_i$	$NP_i$	$x_i$	$f_i$	$NP_i$
1	60	60.00	1	48	48.00
2	52	52.00	2	44	44.00
3	30	26.71	3	19	21.98
4	9	9.75	4	13	7.54
5	0	2.76	5	0	2.48
6	1	0.79			
$TV$	0.02306		$TV$	0.04399	
$a$	1.26080		$a$	1.09764	
$b$	1.45476		$b$	1.19742	
$P_{value}$	0.9625		$P_{value}$	0.7275	

## Programy v jazyku R

Nasledujúci program je kód z jazyka R pre prvú sadu dát od Čebanova.

```
Z<-c(1823,849,194,37)
y=length(Z)
w=sum(Z)
pp<-rep(0,y)
Np<-rep(0,y)
A<-rep(0,y)

#optimalizacia parametra a pre Chi kvadrát vzdialenosť
res<-function(a){
  for(k in 1:y){
    pp[k]=exp(-a)*a^(k-1)/factorial(k-1) #1-...
    pp[y]<-1-sum(pp[1:3])
    Np[k]=sum(Z)*pp[k]
    A[k]=(Z[k]-Np[k])^2/(Np[k])
    P=sum(A)}
  P}
Pmin<-optimize(res,c(0,1))
Pmin

#optimalizacia parametra a pre Totálnu Variáciu
res<-function(a)
{
  for(k in 1:y){
    pp[k]<- exp(-a)*a^(k-1)/factorial(k-1)
    pp[y]<-1-sum(pp[1:y-1])
    Np[k]=sum(Z)*pp[k]
    A[k]=(abs((Z[k]-Np[k])))
    P=sum(A)/(2*w)}
  P}
Smin<-optimize(res,c(0,1))
Smin

#optimalizacia parametra a pre Hellingerovu vzdialenosť
res<-function(a)
{
  for(k in 1:y){
    pp[k]<-exp(-a)*a^(k-1)/factorial(k-1)
    pp[y]<-1-sum(pp[1:y-1])
    Np[k]=sum(Z)*pp[k]
    A[k]=(sqrt(Z[k]/sum(Z))-sqrt(pp[k]))^2
    P=(sum(A)^(1/2))/sqrt(2)}
  P}
HellingerMin<-optimize(res,c(0,1))
HellingerMin
```

```

#Simulované p-hodnoty pre Chi kvadrát
ss=2000
R<-rep(0,ss)
for(e in 1:ss){
m=2903
a=Pmin$minimum
Y<-rep(0,m)
x<-rep(0,m)
Z<-rep(0,m)
while(m>0){
x[m]<-runif(1)
k=1
pp<-rep(0,100)
M=1
while(M>0){
pp[k]<-exp(-a)*a^(k-1)/factorial(k-1)
P=sum(pp)
M=x[m]-P
Y[m]=k
k=k+1}
Z[k-1]=Z[k-1]+1
m=m-1}
Y
Z[y]=length(Y[Y>y-1])
Z[1:y]
A<-rep(0,y)
pp<-rep(0,y)
for(k in 1:y){
pp[k]=exp(-a)*a^(k-1)/factorial(k-1)
pp[y]<-1-sum(pp[1:y-1])
Np[k]=sum(Z)*pp[k]
A[k]=((Z[k]-Np[k]))^2/(Np[k])
P=sum(A)}
R[e]=P
}
R
T=length(R[R>Pmin$objective])/ss
T

#Simulované p-hodnoty pre Totálnu Variáciu
U<-rep(0,ss)
for(e in 1:ss){
m=2903
a=Smin$minimum
Y<-rep(0,2903)
x<-rep(0,2903)
Z<-rep(0,2903)
while(m>0){

```

```

x[m]<-runif(1)
k=1
pp<-rep(0,100)
M=1
while(M>0){
  pp[k]<-exp(-a)*a^(k-1)/factorial(k-1)
  P=sum(pp)
  M=x[m]-P
  Y[m]=k
  k=k+1}
  Z[k-1]=Z[k-1]+1
  m=m-1}
Y
Z[y]=length(Y[Y>y-1])
Z[1:y]
A<-rep(0,y)
pp<-rep(0,y)
for(k in 1:y){
  pp[k]<- exp(-a)*a^(k-1)/factorial(k-1)
  pp[y]<-1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=(abs((Z[k]-Np[k])))
  P=sum(A)/(2*w)}
U[e]=P
}
U
V=length(U[U>Smin$objective])/ss

#Simulované p-hodnoty pre Hellingerovu vzdialenosť
Q<-rep(0,ss)
for(e in 1:ss){
m=2903
p=HellingerMin$minimum
Y<-rep(0,2903)
x<-rep(0,2903)
Z<-rep(0,2903)
while(m>0){
  x[m]<-runif(1)
  k=1
  pp<-rep(0,2903)
  M=1
  while(M>0){
    pp[k]<-exp(-a)*a^(k-1)/factorial(k-1)
    P=sum(pp)
    M=x[m]-P
    Y[m]=k
    k=k+1}
    Z[k-1]=Z[k-1]+1
    m=m-1}
}

```

```

Y
Z[y]=length(Y[Y>y-1])
Z[1:y]
A<-rep(0,y)
pp<-rep(0,y)
for(k in 1:y){
  pp[k]<-exp(-a)*a^(k-1)/factorial(k-1)
  pp[y]<-1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=(sqrt(Z[k]/sum(Z))-sqrt(pp[k]))^2
  P=(sum(A)^(1/2))/sqrt(2)}
Q[e]=P
}
Q
HellingerSimPvalue=length(Q[Q>HellingerMin$objective])/ss

T
V
HellingerSimPvalue

```

Nasledujúci kód je pre 10 textov dolnolužickej srbčiny.

```

Z<-c(48,44,19,13,0)
y=length(Z)
w=sum(Z)
pp<-rep(0,y)
Np<-rep(0,y)
A<-rep(0,y)
B<-rep(0,y)

#optimalizacia parametrov a,b pre Chi kvadrát vzdialenosť
res<-function(X){
  a<-X[1]
  b<-X[2]
  B[1]=1
  B[2]=b
  for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
  for(k in 1:y){
    pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
    pp[y]=1-sum(pp[1:y-1])
    Np[k]=sum(Z)*pp[k]
    A[k]=((Z[k]-Np[k]))^2/(Np[k])
    P=sum(A)}
  P}
Pmin<-optim(c(1.3,1.45),res)
Pmin

#optimalizacia parametrov a,b pre Totálnu Variáciu
res<-function(X){

```

```

a<-X[1]
b<-X[2]
B[1]=1
B[2]=b
for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
for(k in 1:y){
  pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
  pp[y]=1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=(abs((Z[k]-Np[k])))
  P=sum(A)/(2*w)
}
Smin<-optim(c(1.1,1.2),res)
Smin

#Optimalizácia parametrov pre Hellingerovu vzdialenosť
res<-function(X){
  a<-X[1]
  b<-X[2]
  B[1]=1
  B[2]=b
  for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
  for(k in 1:y){
    pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
    pp[y]=1-sum(pp[1:y-1])
    Np[k]=sum(Z)*pp[k]
    A[k]=(sqrt(Z[k]/sum(Z))-sqrt(pp[k]))^2
    P=(sum(A)^(1/2))/sqrt(2)
  }
  HellingerMin<-optim(c(0.8,0.8),res)
  HellingerMin

#Simulované p-hodnoty pre Chi kvadrát vzdialenosť
ss=2000
R<-rep(0,ss)
for(e in 1:ss){
  m=124
  a=Pmin$par[1]
  b=Pmin$par[2]
  Y<-rep(0,m)
  x<-rep(0,m)
  Z<-rep(0,m)
  while(m>0){
    x[m]<-runif(1)
    k=1
    pp<-rep(0,y)
    M=1
    while(M>0){
      pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))

```

```

pp[5]<-1-sum(pp[1:4])
P=sum(pp[1:k])
M=x[m]-P
Y[m]=k
k=k+1}
Z[k-1]=Z[k-1]+1
m=m-1}
Y
Z[y]=length(Y[Y>y-1])
Z[1:y]
A<-rep(0,y)
pp<-rep(0,y)
B[1]=1
B[2]=b
for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
for(k in 1:y){
  pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
  pp[y]=1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=((Z[k]-Np[k]))^2/(Np[k]) #chi kvadrat test
  P=sum(A)}
  R[e]=P
}
R
T=length(R[R>Pmin$value])/ss
T

#Simulované p-hodnoty pre Totálnu Variáciu
U<-rep(0,ss)
for(e in 1:ss){
  m=124
  a=Pmin$par[1]
  b=Pmin$par[2]
  Y<-rep(0,m)
  x<-rep(0,m)
  Z<-rep(0,m)
  while(m>0){
    x[m]<-runif(1)
    k=1
    pp<-rep(0,y)
    M=1
    while(M>0){
      pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
      pp[5]<-1-sum(pp[1:4])
      P=sum(pp[1:k])
      M=x[m]-P
      Y[m]=k
      k=k+1}
      Z[k-1]=Z[k-1]+1
    }
  }
}

```

```

m=m-1}
Y
Z[y]=length(Y[Y>y-1])
Z[1:y]
A<-rep(0,y)
pp<-rep(0,y)
B[1]=1
B[2]=b
for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
for(k in 1:y){
  pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
  pp[y]=1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=(abs((Z[k]-Np[k])))
  P=sum(A)/(2*w)}
U[e]=P
}
U
V=length(U[U>Smin$value])/ss

#Simulované p-hodnoty pre Hellingerovu vzdialenosť
Q<-rep(0,ss)
for(e in 1:ss){
  m=124
  a=Pmin$par[1]
  b=Pmin$par[2]
  Y<-rep(0,m)
  x<-rep(0,m)
  Z<-rep(0,m)
  while(m>0){
    x[m]<-runif(1)
    k=1
    pp<-rep(0,y)
    M=1
    while(M>0){
      pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
      pp[5]<-1-sum(pp[1:4])
      P=sum(pp[1:k])
      M=x[m]-P
      Y[m]=k
      k=k+1}
    Z[k-1]=Z[k-1]+1
    m=m-1}
  Y
  Z[y]=length(Y[Y>y-1])
  Z[1:y]
  A<-rep(0,y)
  pp<-rep(0,y)
  B[1]=1
}

```

```

B[2]=b
for(k in 2:y-1){B[k+1]=B[k]*(b+k-1)}
for(k in 1:y){
  pp[k]=a^(k-1)/((B[k])*genhypergeo(1,b,a))
  pp[y]=1-sum(pp[1:y-1])
  Np[k]=sum(Z)*pp[k]
  A[k]=(sqrt(Z[k]/sum(Z))-sqrt(pp[k]))^2
  P=(sum(A)^(1/2))/sqrt(2)}
  Q[e]=P
}
Q
HellingerSimPvalue=length(Q[Q>HellingerMin$value])/ss

T
V
HellingerSimPvalue

```