

Automatická kontrola textu pre slovenčinu

Ondrej Čičkán

Vedúci projektu: Ing. Marián Šimko PhD.

Automatická kontrola textu

- ◊ Detekcia chýb a ich oprava
- ◊ Typy chýb
 - ◊ Preklepy
 - ◊ Chýbajúca diakritika, interpunkcia
 - ◊ Gramatické chyby
 - ◊ Štylistické chyby
- ◊ Problémy slovenčiny:
 - ◊ Ohybné slovné druhy (inflexívnosť)
 - ◊ Voľné poradie slov vo vete
 - ◊ Veľa výnimiek

Metódy kontroly textu

- ◇ nezávislé od kontextu / závislé od kontextu
- ◇ Využívajúce:
 - ◇ Slovníky (Hunspell)
 - ◇ Pravidlá (LanguageTool)
 - ◇ Štatistiku (Korektor)

Test nástrojov na kontrolu slovenčiny

278 slov

34 chýb

Použitý nástroj / Typ chyby	Neexistujúce slová	Chybné slová		Čiarky	Štýl	Nezaradené	Celkom
		Preklepy	Gramatické				
Bez kontroly	20	5	2	3	2	2	34
Microsoft Word	4	5	2	3	1	1	16
LibreOffice	2	5	2	3	2	2	16
LanguageTool	3	5	2	3	1	1	15
Hunspell	3	5	2	3	2	2	17
Aspell	3	5	2	3	2	2	17
Chrome	3	5	2	3	2	2	17

Počet neopravených chýb

Korektor češtiny

- ◇ <http://ufal.mff.cuni.cz/korektor>
- ◇ Štatistický korektor
- ◇ Využíva kombináciu jazykových modelov založených na:
 - ◇ Slovných tvaroch
 - ◇ Leme
 - ◇ Gramatických kategóriách
- ◇ Model chýb

	Korektor	MS Word
1	91,6%	71,2%
2	97,2%	-
5	98,6%	-

	Korektor	MS Word
Precision	1,0	0,5
Recall	0,77	0,08
F-measure	0,87	0,14

Richter Michal, Straňák Pavel and Rosen Alexandr. *Korektor – A System for Contextual Spell-checking and Diacritics Completion* In Proceedings of the 24th International Conference on Computational Linguistics (Coling 2012), pages 1-12, Mumbai, India, 2012

- ❖ Open source
- ❖ Možnosť vytvoriť podporu pre ďalšie jazyky

Jazykové modely pre slovenčinu

- ◊ Textový korpus
- ◊ Vytvoriť jazykové modely
 - ◊ Pre rôzne črty jazyka (lema, gramatické kategórie)
 - ◊ Lematizátor
 - ◊ Nástroj na určovanie gramatických kategórií
- ◊ Nástroje na tvorbu jazykových modelov
 - ◊ SriLM
 - ◊ KenLM

Model chýb

- ◊ Church & Gale, 1991
- ◊ Textový korpus s chybami
 - ◊ Identifikovať chyby
 - ◊ Len chyby do editačnej vzdialenosti 1
 - ◊ Spočítať počet chýb pre každú operáciu

Testovanie

- ◇ Testovacie dáta:
 - ◇ Časť textového korpusu, ktorý nebol použitý na tréovanie
 - ◇ Diktát