

# Víceúrovňová anotace českého žákovského korpusu

Svatava Škodová<sup>1</sup>    Barbora Štindlová<sup>1</sup>  
Jirka Hana<sup>2</sup>    Alexandr Rosen<sup>2</sup>

<sup>1</sup>Technická Univerzita, Liberec

<sup>2</sup>Karlova univerzita, Praha

Korpling 2011  
Korpusová lingvistika  
Praha, 22.–24. září 2011

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování

# Žákovský korpus

- elektronický soubor jazykových projevů studentů daného jazyka jako jazyka cizího/druhého (Leech 1998)
- 1990 – ICLE (S. Granger, Université catholique de Louvain)

# CzeSL – žákovský korpus češtiny

- první velký žákovský korpus pro slovanský jazyk – slovinština: PiKUST (35 tis. slov)
- první korpus češtiny jako druhého / cizího jazyka
- součást projektu *AKCES* – akviziční korpusy češtiny

# Plánovaný rozsah v roce 2012

- 1 mil. slov
- 3 subkorpusy podle prvního jazyka
- psaná a mluvená část
- všechny úrovně znalosti jazyka podle SERR

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů**
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování

Korpus	Mil. slov	L1	L2	Úroveň	Médium	Anotace
ICLE	3	26	en	pokr.	psaný	část
CLC	35	130	en	všechny	psaný	část
LINDSEI	0,8	11	en	pokr.	mluv.	část
PELCRA	0,5	pl	en	všechny	psaný	část
USE	1,2	sv	en	pokr.	psaný	ne
HKUST	25	zh	en	pokr.	psaný	část
CHUNGDAHM	131	ko	en	všechny	psaný	část
JEFLL	0,7	jp	en	zač.	psaný	část
MELD	1	16	en	pokr.	psaný	ne
MICASE	1,8	různé	en	pokr.	mluv.	ne
NICT JLE	2	jp	en	všechny	mluv.	část
FALKO	0,3	5	de	pokr.	psaný	část
FRIDA	0,2	různé	fr	stř.pokr.	mluv.	část
FLLOC	2	en	fr	všechny	mluv.	ne
PiKUST	0,04	18	sl	pokr.	psaný	ano
ASU	0,5	různé	no	pokr.	psaný	ne
TUFS	znaků: 0,6	různé	jp	všechny	psaný	ne

# Anotace žákovských korpusů

Data nerodilých mluvčích se v žákovských korpusech mohou anotovat dvěma na sobě nezávislými způsoby:

## Lingvistické značkování

- lemmatizace
- slovnědruhová, morfologická, příp. syntaktická anotace
- využití softwarových nástrojů pro analýzu národního jazyka

## Chybová anotace

- manuální
- úroveň, rozsah a koncept chybových anotací se značně odlišují

# Chybová anotace

- přibližně 46 % žakovských korpusů je anotovaných
- selektivní chybová anotace:
  - výslovnost (LeaP)
  - pravopis (TLEC)
  - syntax (AleSKO)
- komplexní chybová anotace:  
ICLE, FRIDA, FALCO, NICT JLE, CzeSL

# Možnosti zachycení chyb

## 1. Rekonstrukce – implicitní zachycení chyb

- chyba v textu je detekována a nahrazena korektní formou
- absence klasifikačního schématu (Fitzpatrick a Seegmiller 2004)
  - výhody
    - anotátor se ho nemusí učit
    - anotování je rychlejší
    - nedochází k chybnému zařazení, příp. přehlížení chyb
  - nevýhody
    - omezený počet anotátorů
    - problematické pro automatickou analýzu
    - problematické pro uživatele

## 2. Klasifikace – explicitní zachycení chyb

- chybová taxonomie
  - identifikace a kategorizace chyb podle předem vymezené chybové typologie
- vždy odráží teoretický koncept, v jehož rámci vznikla

# Typy chybových taxonomií

## Lingvisticky zaměřené taxonomie

- různě podrobné
  - od široce pojatých kategorií (morfologie, lexikum, syntax) ke kategoriím specifickým (pomocná slovesa, pasivum, apod.)
- hierarchicky uspořádané,
  - chybová doména (gramatická, lexikální, stylová)
  - chybová kategorie (např. diakritika, flexe, rod, modus, atp.)
  - slovní druh (POS)

## Taxonomie podle povrchové realizace

- formální typy alternace zdrojového textu (chybějící element, přebývající element, chybně utvořený element, chybné uspořádání)
- často jako komplementární k lingvisticky orientované kategorizaci

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL**
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování

# Chybová anotace v korpusu CzeSL

- problematické jevy v češtině
  - flexe, derivace, shoda, slovosled podle aktuálního členění ap.

## Řešení

- víceúrovňové anotační schéma
- kombinace manuální a automatické anotace

## Automatická anotace

- automatické přiřazování chybových značek na základě porovnání chybných a opravených tvarů
- morfosyntaktické značkování a lemmatizace

Ruská čeština  
Viktor je mladý pan z ~~Polska~~ <sup>Polska</sup>. Studuje ve škole, protože ne umí psát a číst správně. Bydlí na koleji vedle školy, má jednu sestru Irenu, která se učí na univerzitě u profesora Smutneveselého. Bohužel, Viktor není dobrý student, protože spí na lekci, ale jeho sestra <sup>π</sup> píše všechno a vyborně rozumí českou profesora Smutneveselého. <sup>a bízí dělá domácí úkol</sup> Věcra Irena jde na procházku spolu s kamarádem, ale její bratr dělá nic. Jeho čeština je špatná, vim, že se ~~se~~ vrátí ve <sup>Ruská</sup> Polsko a tam bude studovat a pomalu mijs podléhaty.

~~His comrade~~ Kamarad Ireny je Američan a chytrý muž. On ~~sliba~~ miluje Irenu a chce se veit na ní, protože ona je hezká, taky chytrá, rozumí ho a umí vyborně psát.

<li>Viktor je mladý pan z **Polska** Ruska. Studuje **{češtinu}**<in> ve škole, protože ne umí psát a číst správně. Bydlí na koleje vedle školy, má jednu sestru Irenu, která se učí na univerzitě u profesora Smutneveselého. Bohužel, Viktor není dobrým studentem, protože spí na lekci, ale jeho sestra **{píše všechno -> všechno píše}** a výborně rozumí českému profesoru Smutneveselého **{a brzo dělá domácí úkol}**<in>. Večere Irena jde na procházku spolu s kamarádem, ale její bratr dělá nic. Jeho čeština je špatná, vím, že se vrátí ve **Polsko** Rusko a tam bude studovat a pomalu myt podlahy.

<li>Kamarád Ireny je **{Ala}** američan a chytrý muž. On miluje Irenu a chce se vzít na ní. protože ona je hezká, taky chytrá, rozumí ho a umí výborně vařit.

<li>Viktor je mladý pan z **Polska** Ruska. Studuje **{češtinu}**<in> ve škole, protože ne umí **psat** a **číst spravně**. Bydlí na koleje vedle školy, má jednu sestru Irenu, která se učí na **univerzite** u profesora **Smutneveselého**. Bohužel, Viktor není **dobrym** student, protože spí na lekci, ale jeho sestra **{píše všechno -> všechno píše}** a **vyborně** rozumí **českeho** profesora **Smutneveselého** **{a brzo delá domácí ukol}**<in>. Večere Irena jde na **prohaska** spolu z **kamaradem**, ale její bratr dělá nic. Jeho čeština je špatná, vím, že se **vratit** ve **Polsko** Rusko a tam budí studovat u pomalu **myt** podlahy.

<li>**Kamarad** Ireny je **{A|a}**meričan a **chytry muž**. On miluje Irenu a chce se vzít na ní. **protože** ona je hezká, taky **chytra**, rozumí ho a umí **vyborný** vařit.

<li>Viktor je mladý **pan** z **Polska** Ruska. Studuje {češtinu}<in> ve škole, protože **ne umí psát** a **číst správně**. Bydlí na **koleje** vedle školy, má jednu sestru Irenu, která se učí na **univerzite** u profesora **Smutneveselého**. Bohužel, Viktor není **dobrym** student, protože spí na lekci, ale jeho sestra {piše všechno -> všechno píše} a **vyborně** rozumí **českeho profesora Smutneveselého** {a brzo dělá domácí ukol}<in>. **Večeře** Irena jde na **prohaska** spolu **z kamaradem**, ale její bratr **dělá** nic. Jeho čeština je špatná, **vím**, že se **vratit** **ve Polsko Rusko** a tam **budí** studovat **u** pomalu **myt** podlahy.

<li>**Kamarad** Ireny je {A|a}meričan a **chytry muž**. On miluje Irenu a chce **se vzít na ní**. **protože** ona je hezká, taky **chytra**, rozumí **ho** a umí **vyborný** vařit.

# Anotační schéma

## Třírovinný formát a dvoustupňová anotace

umožňuje

- postupnou emendaci
- anotaci chyb v izolovaných tvarech i (nespojitéch) řetězcích

# Roviny anotace

## ROVINA 0

- přepis původního textu

## ROVINA 1

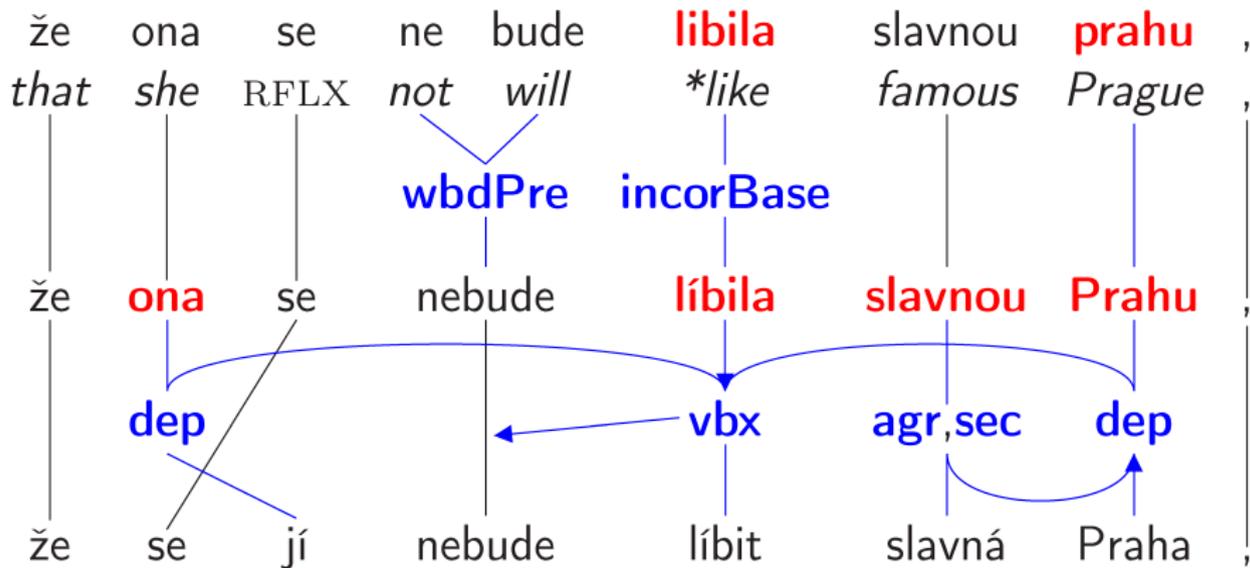
- oprava pravopisných a morfologických chyb izolovaných tvarů
- výsledek:
  - řetězec existujících českých forem
  - věta jako celek může být chybná

## ROVINA 2

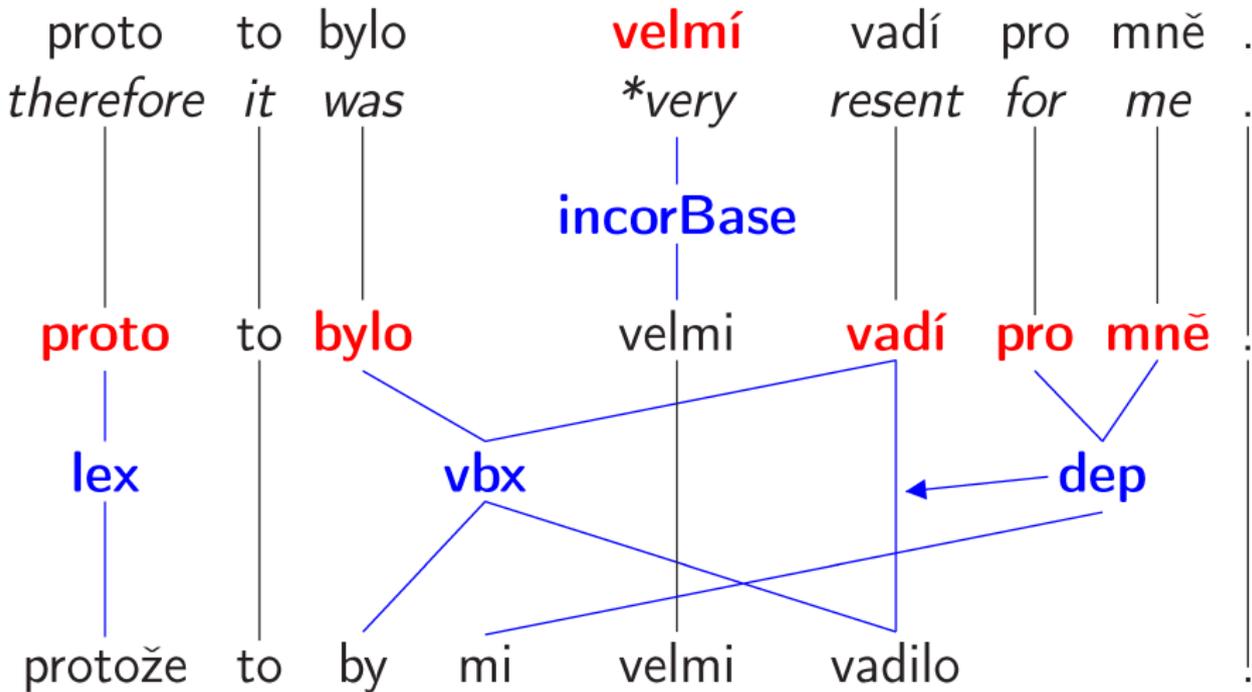
- ostatní typy chyb (syntaktické, lexikální, slovosledné, stylové, v referenci, negaci atd.)
- výsledek:
  - gramaticky správná věta

**Bojal jsme se že ona se ne bude libila slavnou prahu,  
proto to bylo velmi vadí pro mně.**





*that she would not like the famous city of Prague,*



*because I would be very unhappy about it.*



B	j	s	ž	o	s	n	b	l	pr	pr	t	b	v	v	p	m	Č
unk	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
Bál	jsem	se	že	ona	se	bude	líbit	Prahu	proto	to	bylo	velmi	vadí	pro	mně	Česka	
X	X	X	X	X	val	wo	X	val	X	lex	X	cvř	X	X	wo	val	
Bál	jsem	se	že	se	ji	bude	líbit	Praha	protože	to	by	mi	velmi	vadilo			

Proč mám/nemám rád (Č)eskou republiku?

Už se nacházím v české republice až půl roku. toho mě musilo by stačit, abych rozuměl, mám rád to země nebo ne rád. teďko mužů určitě říct, že českou republiku já miluju. tento země má všechna že potřebuju a a moje přítelkyně. Bojal jsem se že ona se ne bude líbit **prahu**, proto to bylo velmi vadí pro mně. Česka republika je krásne místo. tady je hodně hezké pamatek. například pražský hrad a vyšehrad. líbim se moc pražský hrad, protože tam je zámky, který velmi krásne a hezke. take v čechach je dobra příroda a když jsme se procházeli na divoke šarce byli šokováni ~~o~~ z tech krásnych pohledů. Je to nekrásnější místo ve všem bílém světě. take rad že Češi ie dobri

Fit WFR Orig Zoom

miluju. tento země má všechna  
 a a moje přítelkyně. Bojal jsem se  
 že ne bude líbit prahu, proto to bylo velmi  
 vadí pro mně. Česka republika je krásne místo,  
 hezké pamatek, například pražský  
 hrad. líbim se moc pražský hrad, proto

# Chybová taxonomie

- 22 chybových značek doplňovaných manuálně
- 7 chybových značek doplňovaných automaticky

	manuálně	automaticky	celkem
rovina 1	8	1	9
rovina 2	11	6	17
rovina 1 i 2	3	0	3
celkem	22	7	29

- další typy chyb určovaných automaticky
  - na základě porovnání původního tvaru s opraveným

## Anotační strategie

- anotovat gramatické a lexikální charakteristiky jazyka studentů
  - vzhledem ke spisovné normě

## Důvody

Anotace podle formálních kritérií se hodí jako základ pro:

- srovnání s jazykem rodilých mluvčích
- automatickou anotaci
- anotaci komunikativní kompetence, stylu apod.

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace**
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování

# Evaluace

- taxonomie ověřována na dvojmo anotovaném vzorku 10 000 slov
- anotátorská shoda vyšší u chybových kategorií formálně přesně vymezených

chybová značka	$\kappa$
<b><i>incorBase</i></b>	0,75
<b><i>agr</i></b>	0,54

Viz Štindlová (2011).

## Shoda mezi anotátory

9848 slov

<b>značka</b>	<b>jen A1</b>	<b>jen A2</b>	<b>A1 i A2</b>	<i>κ</i>
incor	168	130	894	0,84
incorStem	167	165	559	0,75
incorInfl	173	130	250	0,61
wbd	14	21	45	0,72
fw	25	17	18	0,46
agr	82	99	110	0,54
dep	99	118	87	0,43
neg	11	9	9	0,47
styl	19	14	10	0,38
lex	107	131	74	0,37
use	60	74	19	0,21
sec	45	18	4	0,11

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace**
- 6 Výhled
- 7 Poděkování

# Automatická anotace chybových textů

## Možnosti

- doplnění manuální anotace, morfosyntaktické značkování a POS
- předzpracování chybového textu
- plně automatická anotace

## Experimenty

- emendace pomocí automatického korektoru (zatím asi 82 % shody s anotátory)
- morfosyntaktické značkování chybového textu různými metodami, porovnání výsledků může vést k hypotéze o typu chyby
- automatická syntaktická analýza

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled**
- 7 Poděkování

# Výhled

## Podrobnější specifikace chybového aparátu

- na základě možností automatické detekce chyb
- na základě možností automatické emendace (spell-checker)
- na základě zkušeností s analýzami opřenými o CzeSL

# Obsah

- 1 Žákovský korpus CzeSL
- 2 Anotace žákovských korpusů
- 3 Anotace korpusu CzeSL
- 4 Evaluace
- 5 Automatická anotace
- 6 Výhled
- 7 Poděkování**



## Děkujeme

dalším členům projektového týmu, zejména Karlu Šebestovi, Mileně Hnátkové, Tomáši Jelínkovi, Vladimíru Petkevičovi a Haně Skoumalové.

# Děkujeme za pozornost!