

# CPA, PDEV, SA, LCP, LFP

**Vít Baisa**

seminář NLP

listopad 2012

Finančního úřadu České republiky v rámci programu podpory rozvoje vzdělávání



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ



**Vít Baisa** (seminář NLP)

CPA, PDEV, SA, LCP, LFP

listopad 2012

1 / 6

## CPA a PDEV

- aktuálně projekt DVC – disambiguation of verbs by collocations
- <http://clg.wlv.ac.uk/projects/DVC/>
- Mitkov, Hanks, Orasan (Wolverhampton)
- role FI: technická podpora, hosting, vývoj nového rozhraní
- role Wolverhamptonu: lexikografická anotace

## CPA – anotace slovesa *zlomit*

- anotace v czes2
- dělá se většinou sample (250–500)
- anotace špatně označkovaných dat x
- anotace patternů
- sémantické typy se do ontologie přidávají pouze tehdy, kdy pomáhají rozlišit dva různé významy (patterny)
- podkategorie s, a, f, w



## Jazykový a překladový model pomocí SA, LCP a LFP

- Potřebuji pro libovolný řetězec v textu s četností  $> n$  seznam všech po něm následujících řetězců s četností  $> n$  a seznam po těchto řetězcích následujících řetězců s četností  $> n$ .
- Pokud se vyskytuje řetězec více jak  $n \times$ , je to jedna paměťová jednotka *chunk*.
  - $m$  (3) po sobě následujících chunků – *pracovní paměť*.
  - SA – suffix array
  - LCP – longest common prefix
  - LFP<sup>n</sup> – longest frequent prefix
  - revSA – reverse suffix array

## Překladový model

- SA, LCP a LFP
- explicitní hranice mezi jazyky v datech
- krást | to steal || zmatený | confused || děláš | you are doing ||



Tento projekt je podpořen Evropskou unií v rámci Operačního programu pro konkurenční sílu České republiky.



INVESTICE DO RŮZNOU VZDĚLÁVÁNÍ



Vít Baisa (seminář NLP)

CPA, PDEV, SA, LCP, LFP

listopad 2012

6 / 6