

Towards Semantic Annotation Supported by Dependency Linguistics and ILP

Jan Dědek

Department of Software Engineering, Faculty of Mathematics and Physics,
Charles University in Prague, Czech Republic

Seminář informatiky I2, 2. 11. 2010, MFF UK, Praha
Doktorský projekt Res Informatica

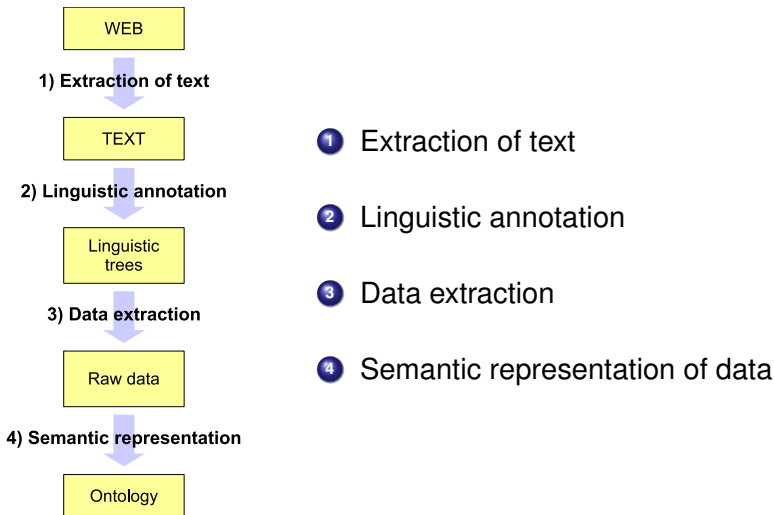
Outline

- 1 Introduction**
 - Our Information Extraction System
 - Linguistics we have used
 - Domain of fire-department articles
- 2 Our Information Extraction Method**
 - Manually created rules
 - Learning of rules
 - Evaluation
- 3 Conclusion**
 - Summary
 - Inter-project cooperation

Introduction to the Presented Work


- Extraction of semantic information from **texts**.
 - In Czech language.
 - Coming from web pages.
- Using of Semantic Web **ontologies**.
 - RDF, OWL
- Exploiting of linguistic tools.
 - **Prague Dependency Treebank** project.
 - **TectoMT** project (ÚFAL MFF UK).
 - **GATE** project (The University of Sheffield).
 - Experiments with the **Czech WordNet**.
- **Rule based** extraction method.
 - Extraction rules \approx linguistic **tree queries**
 - ILP learning of extraction rules

Schema of the extraction process



Linguistics we have used

Layers of linguistic annotation in PDT



- Tectogrammatical layer
- Analytical layer
- Morphological layer
- PDT 2.0 on-line:

<http://ufal.mff.cuni.cz/pdt2.0/>

Sentence:

Byl by šel dolesa.

He-was would went toforest.

Tools for machine linguistic annotation

- 1 Segmentation and tokenization
 - 2 Morphological analysis
 - 3 Morphological tagging
 - 4 McDonald's Maximum Spanning Tree parser
– Czech adaptation
 - 5 Analytical function assignment
 - 6 Tectogrammatical analysis
– Developed by Václav Klimeš
- Available within the **TectoMT**¹ project

¹<http://ufal.mff.cuni.cz/tectomt/>

Example of the web-page with a report of a fire department



Zpravodajství

Informace z resortu o tom, co se stalo, co se děje i co se připravuje

Ministerstvo vnitra
» home » navigace » vyhledávání » změna vzhledu

HZS Jihomoravského kraje

Zubatého 1, 614 00 Brno, telefon 950 630 111,
<http://www.firebrno.cz>
Zpravodajství v roce 2006



15.05.2007

V trabantu zemřeli dva lidé

K tragické nehodě dnes odpoledne hasiči vyjžděli na silnici z obce Česká do Kuřimě na Brněnsku.

Nehoda byla operačnímu středisku HZS ohlášena ve 13.13 hodin a na místě zasahovala jednotka profesionálních hasičů ze stanice v Tišnově. Jednalo se o čelní srážku autobusu Karosa s vozidlem Trabant 601. Podle dostupných informací trabant jedoucí ve z Brna do Kuřimě zřejmě vyjel do protisměru, kde narazil do linkového autobusu dopravní společnosti ze Žďáru nad Sázavou. Ve zdemolovaném trabantu na místě zemřeli dva muži – 82letý senior a další muž, jehož totožnost zjišťují policisté.

Hasiči udělali na vozidle protipožární opatření a po vyšetření a zadokumentování nehody dopravní policií vrak trabantu zaklesnutý pod autobusem pomocí lana odtrhli. Po odstranění střechy trabantu pak z kabiny vyprostilí těla obou mužů. Obě vozidla – trabant i autobus, pak postupně odstranili na kraj vozovky a uvolnili tak jeden jízdní pruh. Únik provozních kapalin nebyl zjištěn. Po 16. hodině pomohli vrak trabantu naložit k odtahu a asistovali při odtažení autobusu. Po úklidu vozovky krátce před 16.30 hod. místo nehody předali policistům a ukončili zásah.



Odkazy

stáří menu

Hasiči

- Generální ředitelství
- hl. m. Praha
- Jihočeský kraj
- Jihomoravský kraj
- Karlovarský kraj
- Královéhradecký kraj
- Liberecký kraj
- Moravskoslezský kraj
- Olomoucký kraj
- Pardubický kraj
- Píseňský kraj
- Středočeský kraj
- Ústecký kraj
- kraj Vysočina
- Zlínský kraj



V této rubrice Zpravodajství

- Aktualizace stránek
- Archiv zpravodajství
- Bleskové zpravodajství RSS
- Boj proti korupci
- Digitalní televize
- Hasiči
- Hlavní zprávy
- Ministerstvo
- Od dopisovatelů (neoficiální)
- Police
- Regiony
- Servis nejen pro novináře
- Schengenská spolupráce
- WebEditorial

Na našem serveru v jiných rubrikách

- Aktuality Národního archivu

Domain of our experiments

- Fire-department articles
- From The Ministry of Interior of the Czech Republic²
- Extensive experiments
 - More than 800 articles
 - 1.2 MB of textual data
 - Extracting information about **injured and killed people**
 - 470 matches of the extraction rule,
200 numeric values of quantity (described later)
- Intensive experiments
 - 50 articles
 - Precisely manually tagged
 - Used of the evaluation of the learning procedure

²<http://www.mvcr.cz/rss/regionhzs.html>

Domain of fire-department articles

Example of processed text

fire

3 amateur units

started at

2.13

finished at 4:03

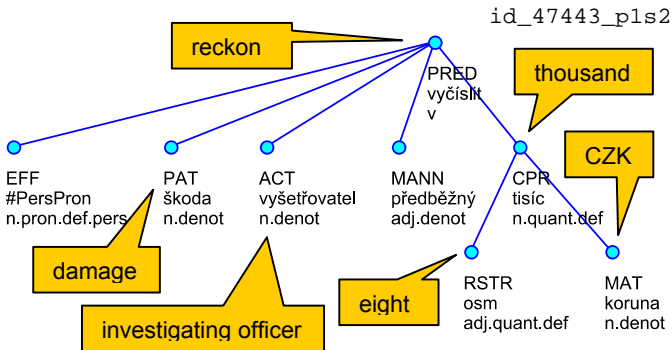
damage 8 000 CZK

id_47443

Požár byl operace na střeše objektu ZS ohlášen dnes ve 2.13 hodin, na místo vyjeli profesionální hasiči ze stanice v Židlochovicích a dobrovolní hasiči z Židlochovic, Žabčic a Přisnotic, Oheň, troinstalaci u chladícího boxu, hasiči dostali pod kontrolu ve 2.32 hodin a uhasili tři minuty po třetí hodině. Příčinou vzniku požáru byla technická závada, škodu vyšetřovatel předběžně vyčíslil na osm tisíc korun.

- Information to be extracted is decorated.
- See the last sentence on the next slide.

Example of a linguistic tree



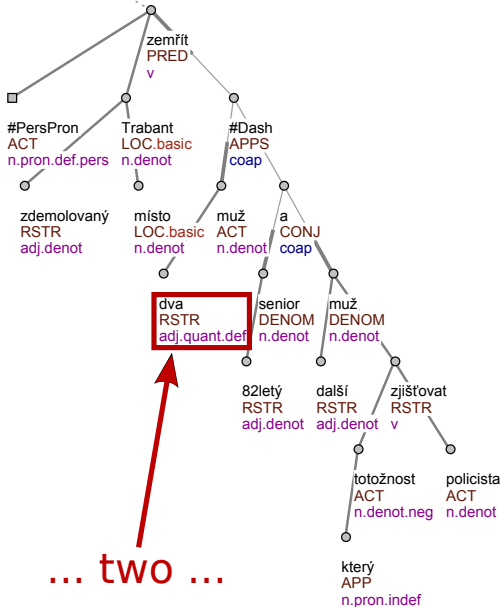
..., škodu vyšetřovatel předběžně vyčísлил na osm tisíc korun.

..., investigating officer preliminarily reckoned the damage to be 8 000 CZK.

- Our IE method uses **tree queries** (tree patterns)

- 1 Introduction**
 - Our Information Extraction System
 - Linguistics we have used
 - Domain of fire-department articles
- 2 Our Information Extraction Method**
 - Manually created rules
 - Learning of rules
 - Evaluation
- 3 Conclusion**
 - Summary
 - Inter-project cooperation

T-jihomoravsky49640.txt-001-p1s4
root

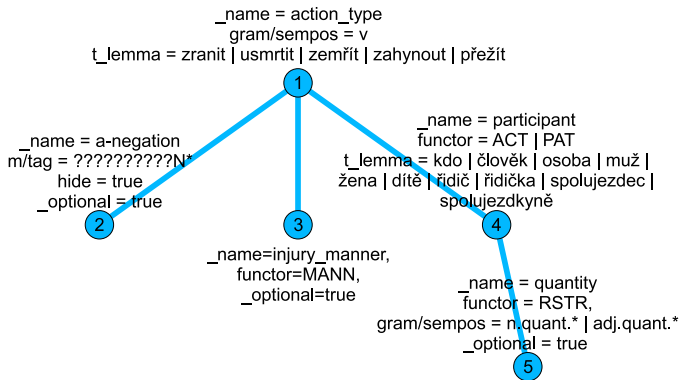


- How to extract the information about **two dead** people?

... two ...

Manually created rules

Extraction rules – Netgraph queries



- Tree patterns on **shape** and **nodes** (on node attributes).
- Evaluation gives **actual matches** of particular nodes.
- **Names** of nodes allow use of references.

Manually created rules

Raw data extraction output

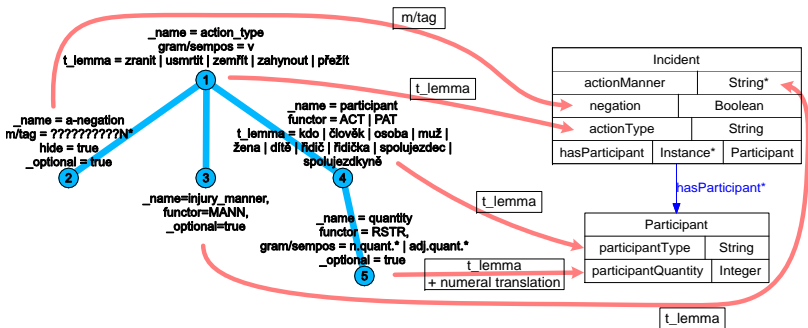
```
<QueryMatches>
  <Match root_id="T-vysocina63466.txt-001-pls4" match_string="2:0,7:3,8:4,11:2">
    <Sentence>
      Při požáru byla jedna osoba lehce zraněna - jednalo se
      o majitele domu, který si vykloubil rameno.
    </Sentence>
    <Data>
      <Value variable_name="action_type" attribute_name="t_lemma">zranit</Value>
      <Value variable_name="injury_manner" attribute_name="t_lemma">lehký</Value>
      <Value variable_name="participant" attribute_name="t_lemma">osoba</Value>
      <Value variable_name="quantity" attribute_name="t_lemma">jeden</Value>
    </Data>
  </Match>
  <Match root_id="T-jihomoravsky49640.txt-001-pls4" match_string="1:0,13:3,14:4">
    <Sentence>
      Ve zdemolovaném trabantu na místě zemřeli dva muži - 82letý senior
      a další muž, jehož totožnost zjišťují policisté.
    </Sentence>
    <Data>
      <Value variable_name="action_type" attribute_name="t_lemma">zemřít</Value>
      <Value variable_name="participant" attribute_name="t_lemma">muž</Value>
      <Value variable_name="quantity" attribute_name="t_lemma">dva</Value>
    </Data>
  </Match>
  <Match root_id="T-jihomoravsky49736.txt-001-p4s3" match_string="1:0,3:3,7:1">
    <Sentence>Čtyřiatřicetiletý řidič nebyl zraněn.</Sentence>
    <Data>
      <Value variable_name="action_type" attribute_name="t_lemma">zranit</Value>
      <Value variable_name="a-negation" attribute_name="m/tag">VpYS---XRⓃA---
      </Value>
      <Value variable_name="participant" attribute_name="t_lemma">řidič</Value>
    </Data>
  </Match>
</QueryMatches>
```



SELECT `action_type.t_lemma`, `a-negation.mtag`, `injury_manner.t_lemma`,
`participant.t_lemma`, `quantity.t_lemma` **FROM** ****extraction rule****

Manually created rules

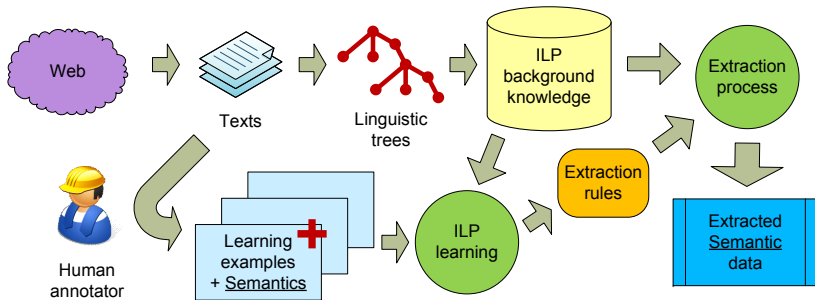
Semantic interpretation of extraction rules



- Determines how particular values of attributes are used.
- Gives semantics to extraction rule.
- Gives semantics to extracted data.

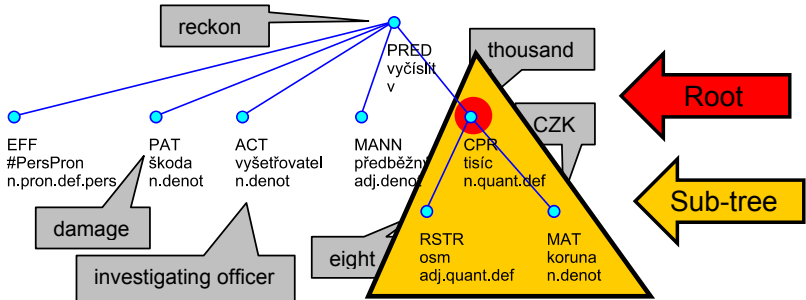
- 1 Introduction**
 - Our Information Extraction System
 - Linguistics we have used
 - Domain of fire-department articles
- 2 Our Information Extraction Method**
 - Manually created rules
 - **Learning of rules**
 - Evaluation
- 3 Conclusion**
 - Summary
 - Inter-project cooperation

Integration of ILP in our extraction process



- Transformation of trees to **logic representation**.
- Today: just **first promising experiments**.

Root/Subtree Preprocessing/Postprocessing (Chunk learning)



..., škodu vyšetřovatel předběžně vyčísлил na **osm tisíc korun**.

..., investigating officer preliminarily reckoned the damage to be **eight thousand Crowns** (CZK).

Examples of learned rules, Czech words are translated.

Example

[Rule 1] [Pos cover = 14 Neg cover = 0]

```
damage_root(A) :- lex_rf(B,A), has_sempos(B,'n.quant.def'),
  tDependency(C,B), tDependency(C,D),
  has_t_lemma(D,'investigator').
```

[Rule 2] [Pos cover = 13 Neg cover = 0]

```
damage_root(A) :- lex_rf(B,A), has_functor(B,'TOWH'),
  tDependency(C,B), tDependency(C,D), has_t_lemma(D,'damage').
```

[Rule 1] [Pos cover = 7 Neg cover = 0]

```
injuries(A) :- lex_rf(B,A), has_functor(B,'PAT'),
  has_gender(B,anim), tDependency(B,C), has_t_lemma(C,'injured').
```

[Rule 8] [Pos cover = 6 Neg cover = 0]

```
injuries(A) :- lex_rf(B,A), has_gender(B,anim), tDependency(C,B),
  has_t_lemma(C,'injure'), has_negation(C,neg0).
```

1 Introduction

- Our Information Extraction System
- Linguistics we have used
- Domain of fire-department articles

2 Our Information Extraction Method

- Manually created rules
- Learning of rules
- Evaluation

3 Conclusion

- Summary
- Inter-project cooperation

Evaluation results

task/method	matching	missing	excess	overlap	prec.%	recall%	F1.0%
damage/ILP	14	0	7	6	51.85	70.00	59.57
damage/ILP – lenient measures					74.07	100.00	85.11
dam./ILP-roots	16	4	2	0	88.89	80.00	84.21
damage/Paum	20	0	6	0	76.92	100.00	86.96
injuries/ILP	15	18	11	0	57.69	45.45	50.85
injuries/Paum	25	8	54	0	31.65	75.76	44.64
inj./Paum-afun	24	9	38	0	38.71	72.73	50.53

- 10-fold cross validation
- Two tasks: ‘damage’ and ‘injuries’
- Root/subtree preprocessing/postprocessing used for ‘damage’ task

1 Introduction

- Our Information Extraction System
- Linguistics we have used
- Domain of fire-department articles

2 Our Information Extraction Method

- Manually created rules
- Learning of rules
- Evaluation

3 Conclusion

- Summary
- Inter-project cooperation

Summary

- Proposed a system for extraction of semantic information
- Based on third party linguistic tools (**TectoMT**³)
- Extraction rules adopted from **Netgraph**⁴ application.
- ILP used for learning rules.
- All methods integrated inside **GATE**⁵.

- Our future research will concentrate on:
 - Extension of the method with WordNet technology.
 - Adaptation of this method on **other languages**.
 - Evaluation of the method on **other datasets**.

³<http://ufal.mff.cuni.cz/tectomt/>

⁴<http://quest.ms.mff.cuni.cz/netgraph/>

⁵<http://gate.ac.uk/>

Inter-project cooperation

- Mainly with **I-3 Matematická lingvistika** group
- **Directly** with David Mareček
- **Indirectly** with all participants of the linguistic projects

- Making all the linguistic tools working, updates
- Planned feedback in the future
(**comparison** of linguistic tools)
- **Porting** PDT formalism and TMT tools to the GATE platform
(side effect of our work, but may be useful in the future).