

Evaluation and Error Analysis of Rule-based Paraphrase Generation for Czech

Veronika Burgerová Aleš Horák

Natural Language Processing Centre
Faculty of Informatics, Masaryk University
Botanická 68a, 602 00, Brno, Czech republic
`{xburger,hales}@fi.muni.cz`

RASLAN 2019

Overview

1 Introduction

2 The Watsonson Project

3 Experiments and Evaluation

4 Future Work

Introduction

- **Paraphrase generation** - useful for several NLP applications
 - Machine translation
 - Text summarization
 - ...
- Rule-based and machine learning methods
- **Evaluation** of rule-based paraphrasing system for Czech
- Working with **individual modules**

The Watsonson Project

- A **game with a purpose** by Zuzana Nevěřilová (CICLING 2014, RASLAN 2013)
- Generates **paraphrases and entailments** from a given sentence

The Watsonson Project

Shenlock Holmer a Dr. Watsonson pátrají společně

Drahý Holmere, jaký případ právě řešíte?



Řekněte Watsonsonovi o novém případu

Řekněte dr. Watsonsonovi, že

- má mluvit dál / je šikovný / je nemožný
- mu poradíte / se vrátíte ke starému případu
- mu popišete nový případ
- už nemáte čas ani trpělivost

Hra



Úroveň: 0
Body: 0
Detektiv: Jméno

Watsonsonův
mozek
Paměť



Hypotézy

Dedukční schopnosti



The Watsonson Project

Pane Holmere, řekl jste: Drahý Watsonsone, zopakujme si, co o případu víme: Petr stál na zastávce a čekal na autobus. Nudil se a tak si zapálil cigaretu. Autobus přijel s půlhodinovým zpožděním. Petr nastoupil a autobus odjel. Od té doby Petra nikdo neviděl.

Má Watsonson pravdu, když myslí, že:

Petr stál na zastávce. ✓ ✗ ☹

Petr čekal na autobus. ✓ ✗ ☹

Petr se nudil. ✓ ✗ ☹

Petr si zapálil cigaretu. ✓ ✗ ☹

Autobus přijel s půlhodinovým zpožděním. ✓ ✗ ☹

Petr nastoupil. ✓ ✗ ☹



Pokračovat

Modules

- Wordnet
- Wordhyp
- Word order
- Aara
- Verbinfer

Wordnet and Wordhyp

- **Wordnet** - uses data from the Czech Wordnet for **synonym** replacement
- Recursively - **wordhyp** module for **hypernym** replacement
- No word sense identification

Example

- Input: Pejsci si chtěli hrát s **dětmi**, ale žádné děti venku nenašli.
(Dogs wanted to play with **children** but they found no children outside.)
- Wordnet: Pejsci si chtěli hrát s **děcky**.
(Dogs wanted to play with **kids**.)
- Wordhyp: Pejsci si chtěli hrát s **lidmi**.
(Dogs wanted to play with **people**.)

Word order

- **Reorders** the sentence **constituents**
- Generates phrases with **all possible orders**

Example

Input: Pejsci si chtěli hrát s dětmi, ale žádné děti venku nenašli.

(Dogs wanted to play with children but they found no children outside.)

Wordorder: Nenašli **oni** žádné děti venku.

(**They** did not find any children outside.)

Aara

- Partial **anaphora resolution**
- Replaces **pronomial objects** or subjects by their **antecedents**
- Resolves **zero subjects**

Example

Input: Pejsci si chtěli hrát s dětmi, ale žádné děti venku nenašli.

(Dogs wanted to play with children but **they** found no children outside.)

Aara: **Pejsci** nenašli žádné děti venku.

(**Dogs** found no children outside.)

Verbinfer

- Using Czech verb valency lexicon VerbaLex
- Verb frame inference of 3 types:
 - equality
 - effect
 - precondition
- Can result in new facts

Example

Input: Pejsci si chtěli hrát s dětmi, ale žádné děti venku **nenašli**.
(Dogs wanted to play with children but they **found** no children outside.)

Verbinfer: **Neobjevili** žádné děti venku.
(They **discovered** no children outside.)

Input dataset

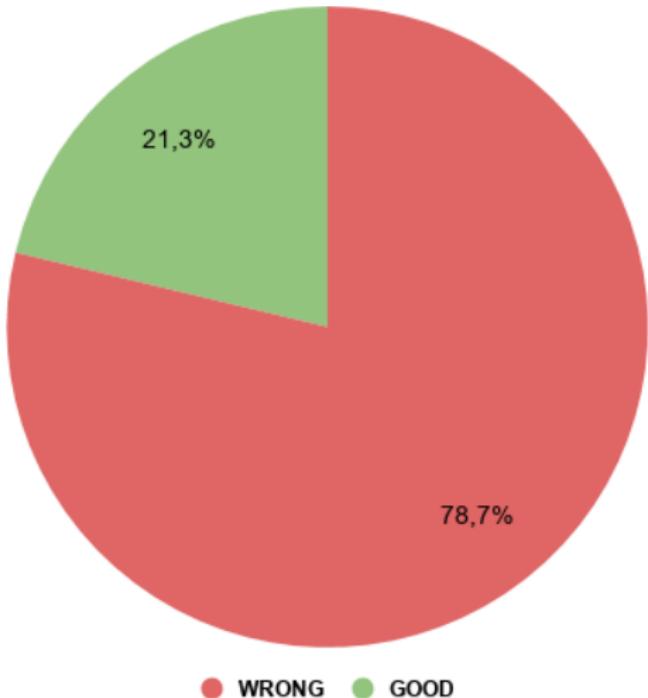
- 40 sentences of various length
- Simple made up phrases or extracted from Czech children tales
- Input examples:

- *Máma upekla koláč.*
- *Pejsek s kočičkou se měli moc rádi a bydleli spolu už spoustu let.*
- *Do paneláku na sídlišti se přistěhoval nový kluk Jakub.*

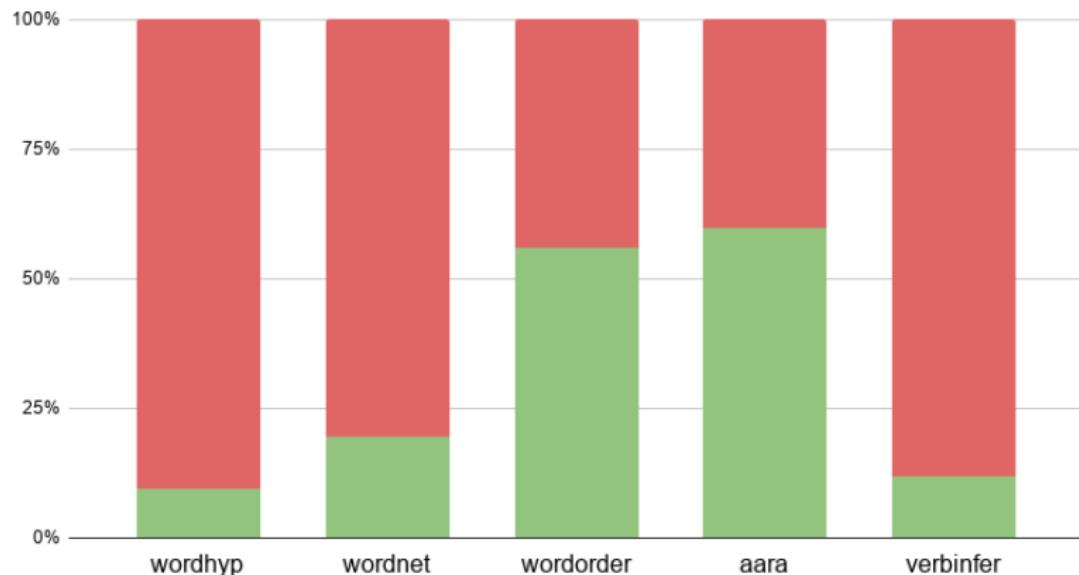
- Processed by morphological analyzer/generator, morphological tagger and syntactic parser
- Stored in JSON format - input to each evaluated module

Evaluation

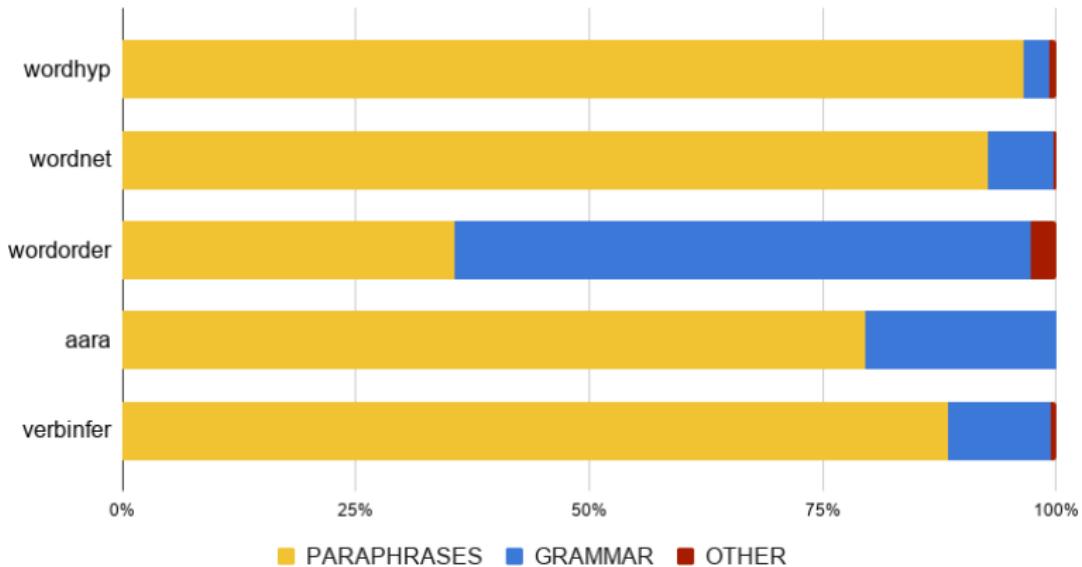
Module	Paraphrases
wordhyp	557
wordnet	488
wordorder	166
aara	97
verbinfer	206
All	1,514



Evaluation - Individual Scores



Error Analysis



Results

- Most of the incorrect paraphrases - word replacement
- Repeated across all modules:
 - ① Prepositions

Example

- Foxlík slyšel někom nedobré. (Foxlík heard someone bad.)
- Krteček přespával hluboko na zemí. (The mole slept deep on the ground.)

② Dependencies

Example

Original meaning: Drak má sedm hlav. (Dragon has seven heads.)
Paraphrase: Ten pejsek sedm hlav má. (The dog has seven heads.)

- Primary source - syntactic parsing phase

Future Work

- Improvement of modules and preprocessing
- New types of paraphrasing methods