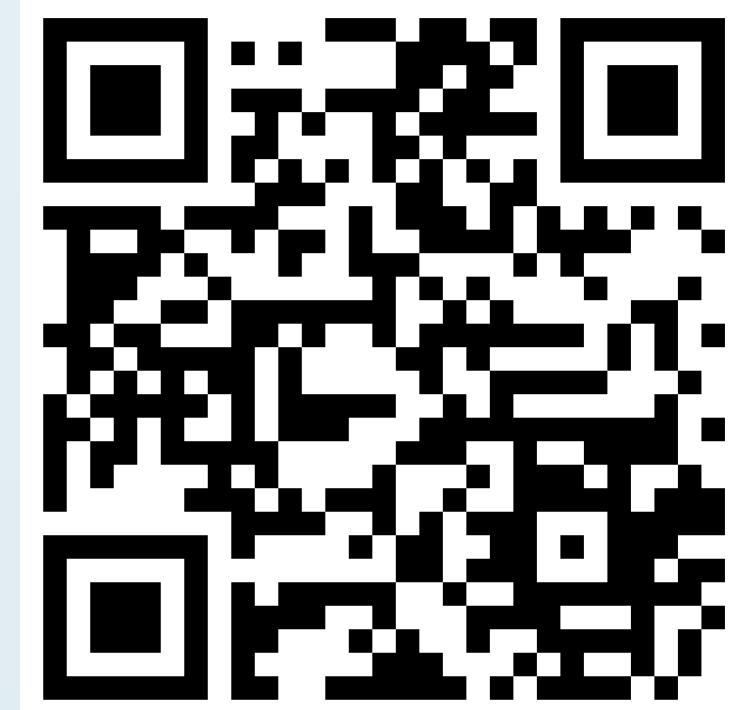


# Querying Multi-word Expressions Annotation with CQL



Natalia Klyueva, Anna Vernerová, Behrang QasemiZadeh  
natalia.klyueva@polyu.edu.hk, vernerova@ufal.mff.cuni.cz, zadeh@phil.hhu.de

## Motivation

Querying corpora with multi-word expression (MWE) annotation using a concordance system.

## PARSEME data

### PARSEME corpus version 1.0:

Bulgarian, Czech, Farsi, French, German, Greek, Hebrew, Hungarian, Italian, Lithuanian, Maltese, Polish, Brazilian Portuguese, Romanian, Slovene, Spanish, Swedish and Turkish

- idioms (ID)
- light verb constructions (LVC)
- inherently reflexive verbs (IRFLV)
- verb-particle constructions (VPC)
- OTH (other)

### Two files: .conllu and .parsemetsv

1 Tím ten DET PD Case=Ins Gender=Masc Neut Number=Sing PronType=Dem	...	1 Tím	...	1
2 pádem pád NOUN NN Animacy=Inan Case=Ins Gender=Masc Negative=Pos Number=Sing	...	2 pádem	...	1:LVC
3 máme mít VERB VB Mood=Ind Neg=Pos Number=Plur Person=1 Tense=Pres VerbForm=Fin Voice=Act	...	3 máme	...	1
4 problém problém NOUN NN Animacy=Inan Case=Acc Gender=Masc Negative=Pos Number=Sing	...	4 problém	...	1
5 se s ADP RV AdpType=Voc Case=Ins	...	5 se	...	
6 silniční silniční ADJ AA Case=Ins Degree=Pos Gender=Fem Negative=Pos Number=Sing	...	6 silniční	...	
7 dani daň NOUN NN Case=Ins Gender=Fem Negative=Pos Number=Sing	...	7 dani	nsp	
8 . PUNCT Z: _	...	8 .	...	

## Format conversion

Attributes representing the MWE annotation:

- **mwe** MWE type, e.g. LVC, ID
- **mwe\_order** with values **first**, **cont** (continuation)
- **mwe\_order\_new** with values **first**, **cont**, **last**
- **mwe\_id** id of the MWE, unique within a sentence
- **mwe\_lemma** concatenation of lemmas

1 Tím ten DET PD ... - - - - - -	1 Tím	...	1
2 pádem pád NOUN NN ... - - - - - -	2 pádem	...	1:LVC
3 máme mít VERB VB ... LVC first first 1 mít problém	3 máme	...	1
4 problém problém NOUN NN ... LVC cont last 1 mít problém	4 problém	...	1
5 se s ADP RV AdpType=Voc Case=Ins	5 se	...	
6 silniční silniční ADJ AA Case=Ins Degree=Pos Gender=Fem Negative=Pos Number=Sing	6 silniční	...	
7 dani daň NOUN NN Case=Ins Gender=Fem Negative=Pos Number=Sing	7 dani	nsp	
8 . PUNCT Z: _	8 .	...	

Figure 1: Simple occurrence of VMWE in Czech

Les œuvres	... - - - - - -	1 Tím	...	1
d'	... - - - - - -	2 pádem	...	1:LVC
Abbas	... - - - - - -	3 máme	...	1
Kiarostami	... - - - - - -	4 problém	...	1
font régulièrement	ID;LVC;LVC first;first;first first;first;first 1;3;2 faire le objet;faire le objet festival;faire le objet exposition	5 se	...	
1' objet	ID;LVC;LVC cont;cont;cont cont;cont;cont 1;3;2 faire le objet;faire le objet festival;faire le objet exposition	6 silniční	...	
d' expositions	ID;LVC;LVC cont;cont;cont last;cont;cont 1;3;2 faire le objet;faire le objet festival;faire le objet exposition	7 dani	...	
ou de festival ,	cont last 3 faire le objet festival	. PUNCT Z: _	...	

Figure 2: Representation of overlapping VMWEs

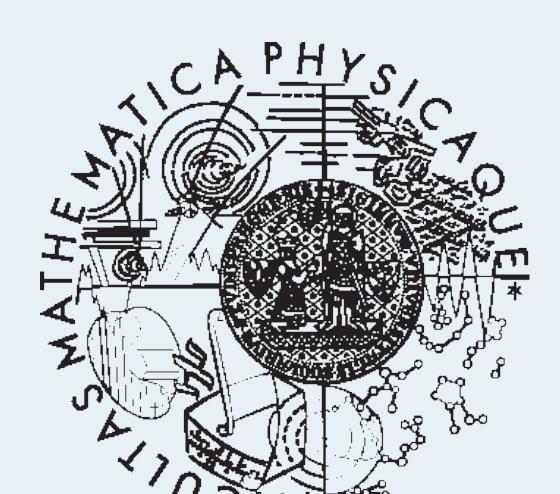
## Query systems

The converted vertical format is suitable for any instance of the Manatee-open corpus search engine. The data is currently available through two front-ends. Both use the same query language, namely CQL.



## Find Out More

<http://ufal.mff.cuni.cz/lindat-kontext/parseme-mwe>



CHARLES UNIVERSITY  
Faculty of mathematics  
and physics



THE HONG KONG  
POLYTECHNIC UNIVERSITY  
香港理工大學

HEINRICH HEINE  
UNIVERSITÄT DÜSSELDORF

## Querying the data in KonText

kon text

Query Corpora Save Concordance Filter Frequency Collocations View Help

Corpus: Parseme VMWE 1.0 - German

Search in the corpus

word

Corpus: Parseme VMWE

Query Type: CQL

CQL: insert 'v\_thin'

In CQL mode you can see a list of all available attributes; most are taken directly from the .conllu files, the last four contain the VMWE annotation

Default attribute: word Tagset summary

Specify context: see a list of all available attributes; most are taken directly from the .conllu files, the last four contain the VMWE annotation

Specify query according to the meta-information

Search

Figure 3: List of attributes for CQL query

- [mwe\_order="first"]  
find the first token in each MWE annotated in the corpus
- [lemma="faire" & mwe!="\_"]  
find a particular word annotated with any category of MWE
- [mwe="LVC" & upostag="VERB"]  
find the verbs in light verb constructions
- [mwe\_lemma="faire partie"]  
search by a concatenation of the lemmas of words belonging to the MWE (in the order in which they appear in the text)
- [mwe\_order\_new="first"] [mwe\_order\_new="cont"]\* [mwe\_order\_new="last"]  
display and highlight continuous MWEs consisting of at least two words
- 1:[mwe\_order\_new="first"] []\* 2:[mwe\_order\_new="last"] & 1.mwe\_id=2.mwe\_id within <s/>  
matches each MWE consisting of at least two words together with any words lying between its first and last word

kon text

Query Corpora Save Concordance Filter Frequency Collocations View Help

Corpus: Parseme VMWE 1.0 - Czech | Query: LVC, first (2,887 hits)

Lemmas Node forms Doc IDs Text Types Custom...

Hits: 2,887 | I.p.m. 3,464,98 (related to the whole "parseme\_cs\_a") | ARF: 1,711,19 | Res: 1 / 73 ►►

Line selection: simple ▾ Display options

train	musí v případě nouze jet vlastním autem. Tím pádem	má problem se silniční daní. Víme, že jste na
train	naši zaměstnanci nedosahují takových kvalit, jaké potřebují. Stejný	má i řada našich soukromých podnikatelů. Mají cílem nemají
train	majitelé našich soukromých firem a nakonec i představitelé firem zahraničních	májí dojem, že v této republice nejsou schopni lidé.
train	tvrdí, že každý stupně nad 20 °C znamená	zvýšení spotřeby energie o 6 %. Nedívajte se, že
train	roce už bude stát gigajoul nejméně 220 Kč. Pak	dá cena tepla v tryskový let. Podle prognózy Moravskoslezských
train	Draža a levná Výroba tepla je nákladná. Reditel Nováček	vyslovuje zásadní nesouhlas se způsoby regulací politiky Ministerstva financí ČR.
train	více? Reditel Paprská navrhuje na pohled nepopulární opatření ke	vylepšení spotřeby energie o 10 tisíc Kč ročně. Opatření by mělo
train	zlepšení současných situací. Zdražit ceny paliv o 100 %.	změnit chování spotřebitele paliv, kteří ještě stále spíše investují
train	oproti ostatním státům odhadují odborníci za ČR. Opatření ke	znižení spotřeby jsou prozatím značně nákladná. Zateplení 1 m 2
train	optimalizaci topení. Zlepšení izolačních vlastností obytných domů může přinést	spotřebě tepla pro otop zhruba o dvacet procent, růžá
train	měřidlo je velmi nákladná. Lepší je podle předsedova názorů	pozornost optimalizaci provozu topných soustav. Prozatím jsou některé byty
train	předložit nepřijatelné podmínky, ale jeho monopolní postavení dnužitivo přinutí	smourovat, užavřít. Jinak nebude mit druhovník teplo ani dotaci.
train	tel.: (069) 611 2526.	informace o výjimkách ze zákazu podle odbor městského hospodářství, tel.
train	jeho dotazy v nejkratším čase zodpoví. Zároveň s hovorem	referent na svůj monitor potřebné informace o volajícím zákazníkovi,
train	hrazené denními zálohami. Ve stejný den je termín pro	Daně z přidané hodnoty: Podání přiznání a daň za
train	měsíční stáž, která byla moží první návštěvou Kanady,	měl jsem o této zemi určitě představy, zejména o ohromné

Figure 4: Click "Frequency->Node forms" to sort according to a token frequency