

Multilingual Ontology Matching based on Wiktionary Data Accessible via SPARQL Endpoint



Санкт-Петербургский институт
информатики и автоматизации РАН



Фейю Лин

feiyu.lin



jth.hj.se

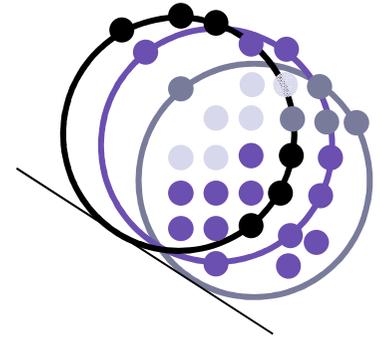
Крижановский Андрей

andrew.krizhanovsky

gmail.com



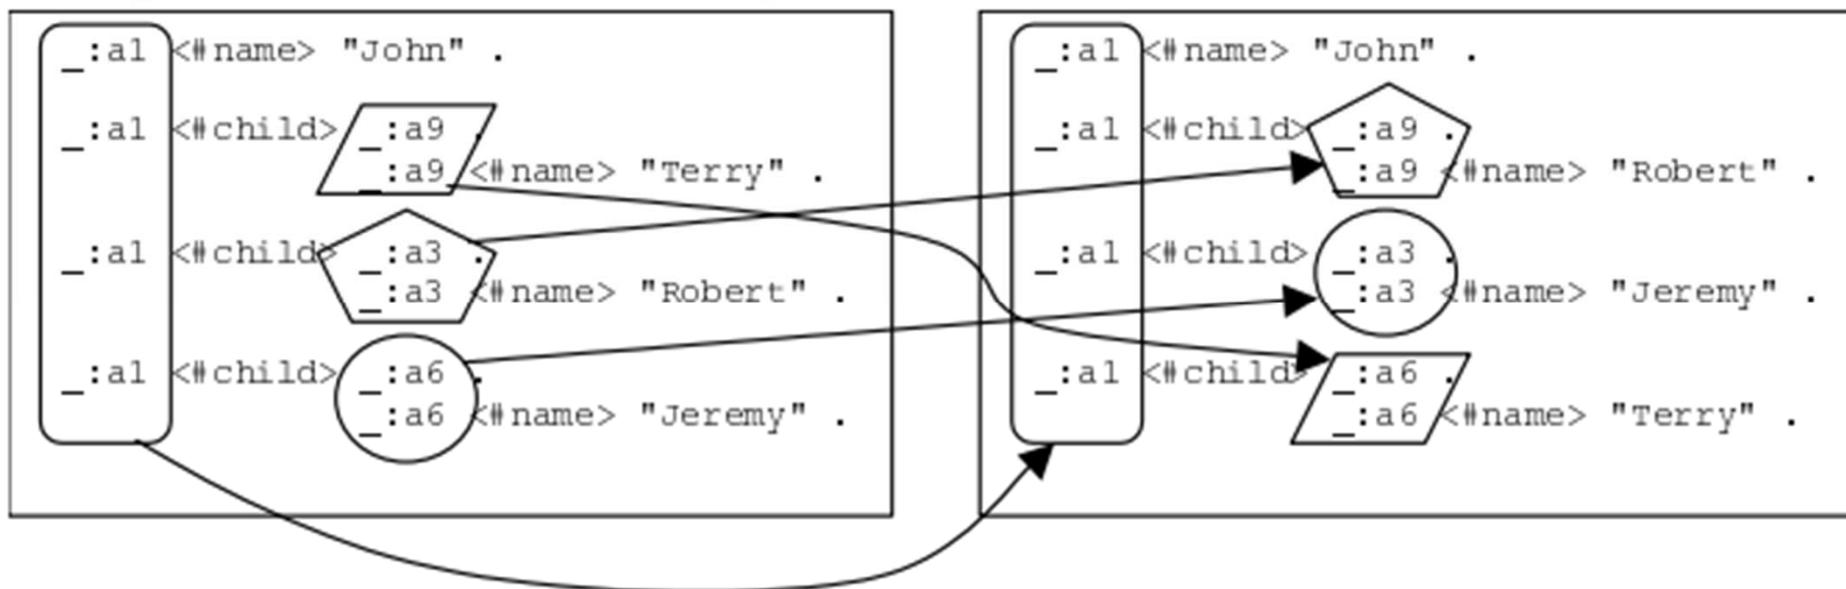
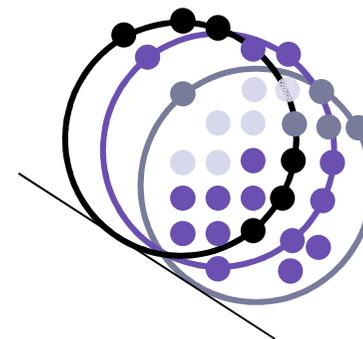
Содержание



- Ontology matching
- Викисловарь
- SPARQL
- Отображение онтологий на разных языках



Multilingual Ontology matching

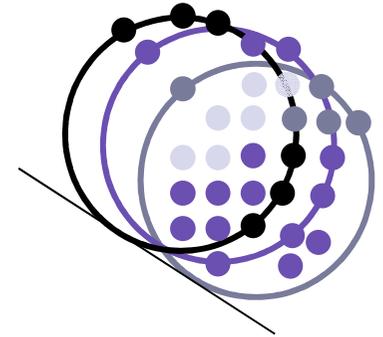


RDF / XML файл 1

RDF / XML файл 2

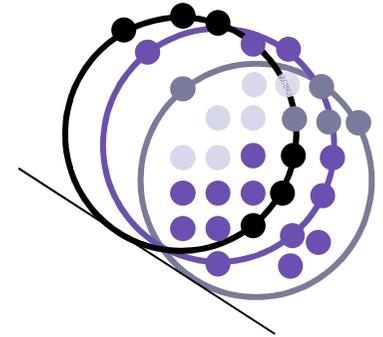


Постановка задачи



- Выполнить отображение онтологий на разных языках (англ., фр.)
 - Перевести с помощью:
 - Google Translate API
 - **Викисловарь** (машинно-читаемый словарь)
- Сравнить качество перевода

Викисловари



Викисловарь –
многофункциональный
многоязычный
словарь и тезаурус

Грамматический
Толковый
Этимологический
Переводной

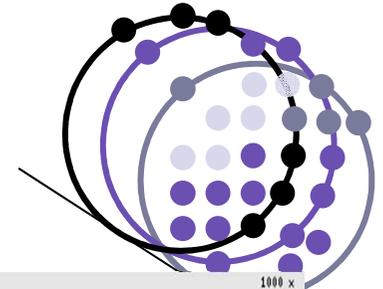
Wiktionary

| | |
|----------------------------------------------------------------------|-------------------------------------------------------------------|
| Français <i>Le dictionnaire libre</i> 856 000+ articles | English <i>The free dictionary</i> 841 000+ articles |
| Tiếng Việt <i>Từ điển mở</i> 227 000+ mục từ | Türkçe <i>Özgür sözlük</i> 208 000+ madde |
| Русский <i>Свободный словарь</i> 137 000+ статей | Ido <i>La libera vortaro</i> 137 000+ artikli |
| 中文 自由的多语言词典 116 000+ 条词条 | Ελληνικά <i>To Eleúthero Lexikó</i> 107 000+ λήμματα |
| தமிழ் <i>கட்டற்ற அகரமுதலி</i> 102 000+ கட்டுரைகள் | Polski <i>Wolny słownik</i> 93 000+ stron |

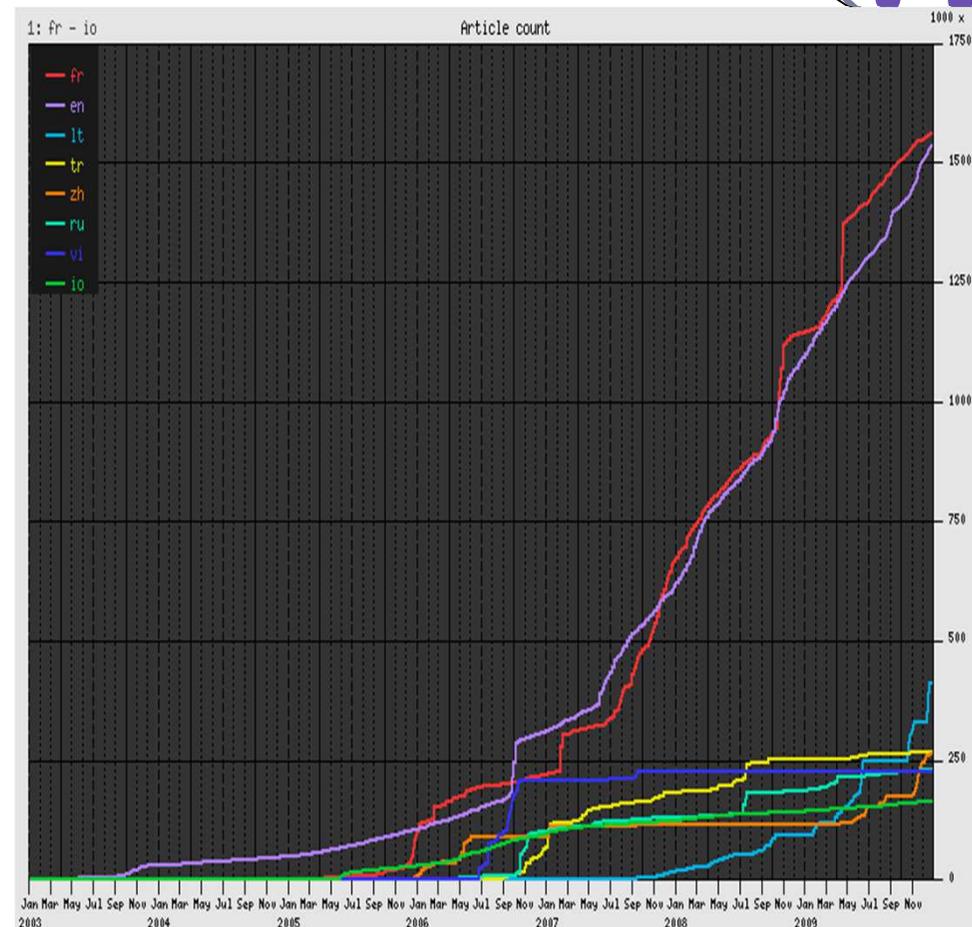
a multilingual free encyclopedia
Wiktionary
[ˈwɪkʃənri] n., a wiki-based Open Content dictionary
Wilek [ˈwɪl kɔɪl]



Развитие Викисловарей



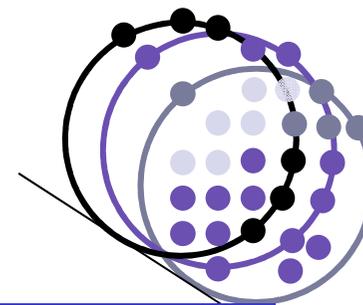
- + Первым появился English Wiktionary в декабре 2002 г.
- + Проект Русский Викисловарь запущен в мае 2004 г.



Восемь самых больших
Викисловарей (2003-2010)



10 крупнейших* (из 170) Викисловарей

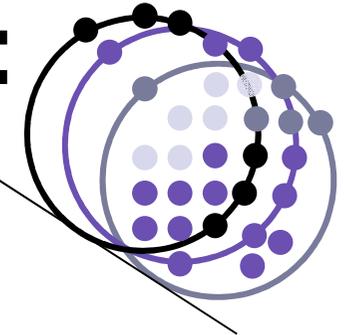


| N | Языковая версия | Словарных статей | Администраторов | Активных редакторов |
|----|-----------------------------------|------------------|-----------------|---------------------|
| 1 | Английский Викисловарь | 2 639 367 | 90 | 980 |
| 2 | Французский | 2 081 306 | 23 | 314 |
| 3 | Китайский | 1 197 238 | 8 | 44 |
| 4 | Малагасийский | 739 456 | 2 | 8 |
| 5 | Литовский | 562 276 | 4 | 22 |
| 6 | Русский | 300 332 | 7 | 174 |
| 7 | Турецкий | 278 631 | 6 | 55 |
| 8 | Польский | 250 385 | 26 | 85 |
| 9 | Тамильский | 234 568 | 12 | 47 |
| 10 | Корейский | 229 410 | 1 | 20 |

* По данным на октябрь 2011

Английский Викисловарь:

Число словарных статей по языкам (Многоязычность)



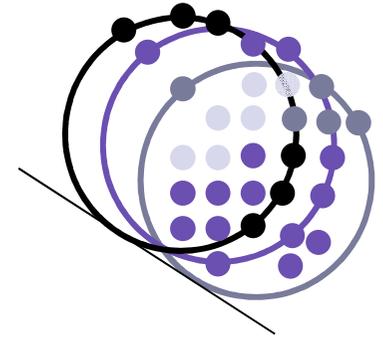
| Раздел Английского Викисловаря | Число словарных статей |
|-----------------------------------|------------------------|
| Латинский | 377 791 |
| Итальянский | 318 707 |
| <i>Английский</i> | <i>304 483</i> |
| Французский | 132 423 |
| Финский | 97 741 |
| и так далее... | |

- Словарные статьи о словах 433 языков.
- Переводы английских слов – на 235 языков.

Дамп словаря от 18 июня 2011 г.



Машинно-читаемый словарь на основе Английского Викисловаря: Раздел переводов



| | Английский Викисловарь | Machine-readable (MRD) |
|---------------------------------------------------|---------------------------|------------------------------------------------|
| Словарных статей | 2 651 524 | 2 149 177 |
| Число переводов с Английского на другие языки | ? | 756 168 |
| Языков (> 1 000 переводов) | ? | 68 |
| Формат данных | Разметка Wiki / XML | Реляционная БД |
| Противоречия и ошибки ввода данных | Есть | Нет (проверка структуры статьи парсером) |
| Программный интерфейс (API) для перевода слова | Нет | Есть |

search

Go

Search

navigation

- [Main Page](#)
- [Community portal](#)
- [Preferences](#)
- [Requested entries](#)
- [\[R\] Recent changes](#)
- [\[X\] Random entry](#)
(by language)
- [Help](#)
- [Donations](#)
- [Contact us](#)

French

Noun

fleur *f* (plural **fleurs**)

1. (*botany*) Flower; bloom; blossom; collectively, the reproductive organs and the envelope which surrounds them in **angiosperms** (also called "flowering plants").

*Je suis allé cueillir une **fleur** dans les champs.*

I went to pick a flower in the fields.

Synonyms

- (*flowering plant*): **angiosperme**

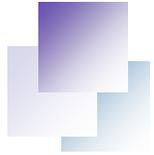
Hyponyms

- (*flower, bloom, blossom*): **bractée**, **carpelle**, **étamine**, **fleuron**, **pédoncule**, **pétale**, **pistil**, **sépale**, **tépale**

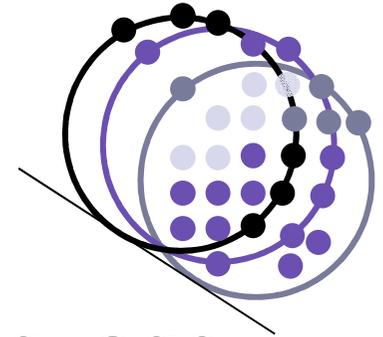


An example of epilobium flowers (*fleurs d'épilobes*)

| Слово | Язык (код) | Часть речи | Число сем. отн. | Число типов сем. отн. | Число значений |
|-------|-------------|------------|-----------------|-----------------------|----------------|
| fleur | French (fr) | Noun | 25 | 4 | 6 |



SPARQL

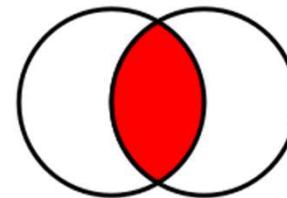


- **SPARQL Protocol and RDF Query Language**
- **RDF язык запросов:**

- Тройка, триплет (?X Отношение ?Y)

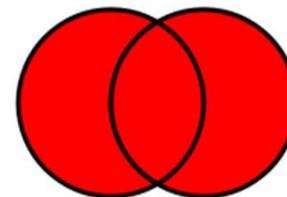
- Конъюнкция (A ; B.)

- `SELECT ?x WHERE { ?A Relation1 ?x ;
?x Relation2 ?B . }`



- Дизъюнкция (A. B.)

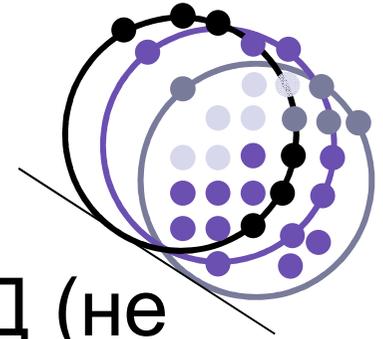
- `SELECT ?x WHERE { ?A Relation1 ?x .
?x Relation2 ?B . }`



- **Дополнительные шаблоны для уточнения поиска.**



Платформа D2RQ

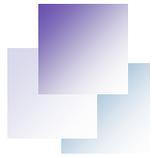


- D2RQ представляет реляционную БД (не RDF) как виртуальный RDF граф

1. Создать файл отображения (MySQL - RDF)
2. Запустить MySQL и сервер-D2RQ
3. Запустить запросы SPARQL

- Инструкции: D2RQ и данные Викисловаря

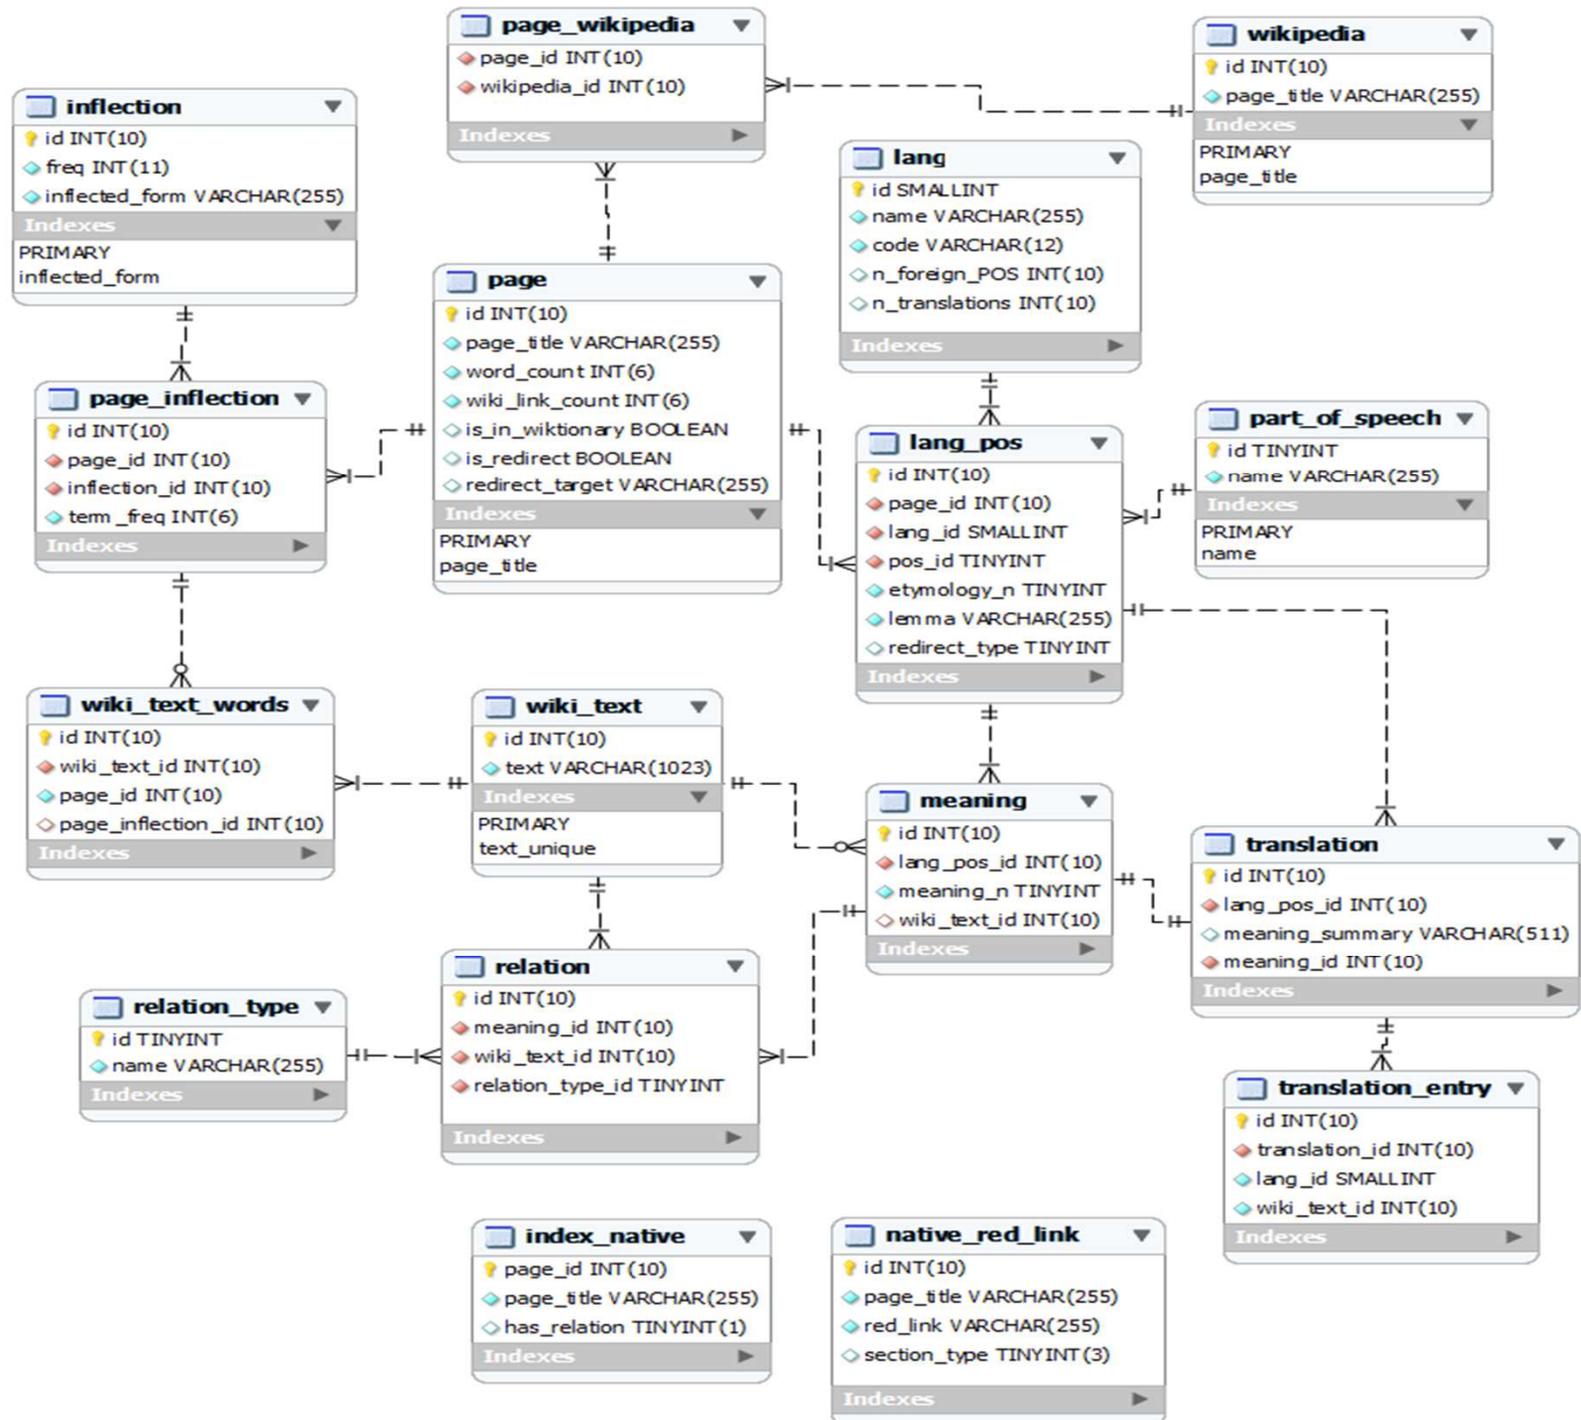
<http://code.google.com/p/wikokit/wiki/d2rqMappingSPARQL>



Wiktionary

MRD

database



Получить толкование из Викисловаря по слову и языку
(SPARQL запрос)

| page |
|-------------------------|
| id INT(10) |
| page_title VARCHAR(255) |

| lang_pos |
|------------------|
| id INT(10) |
| page_id INT(10) |
| lang_id SMALLINT |
| pos_id TINYINT |

```
SELECT ?langId ?pageId ?langPosId ?meaningId  
?wikiTextIdDef ?definition  
WHERE {
```

```
  ?lang wikpa:lang_code "en";  
  wikpa:lang_id ?langId.
```

| lang |
|-------------------|
| id SMALLINT |
| name VARCHAR(255) |
| code VARCHAR(12) |

```
  ?page wikpa:page_page_title "dog";  
  wikpa:page_id ?pageId.
```

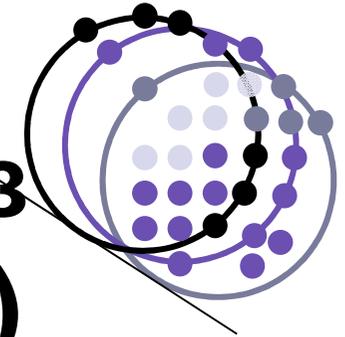
```
  ?lang_pos wikpa:lang_pos_page_id ?pageId;  
  wikpa:lang_pos_lang_id ?langId;  
  wikpa:lang_pos_id ?langPosId.
```

```
  ?meaning wikpa:meaning_id ?meaningId;  
  wikpa:meaning_lang_pos_id ?langPosId;  
  wikpa:meaning_wiki_text_id ?wikiTextIdDef.
```

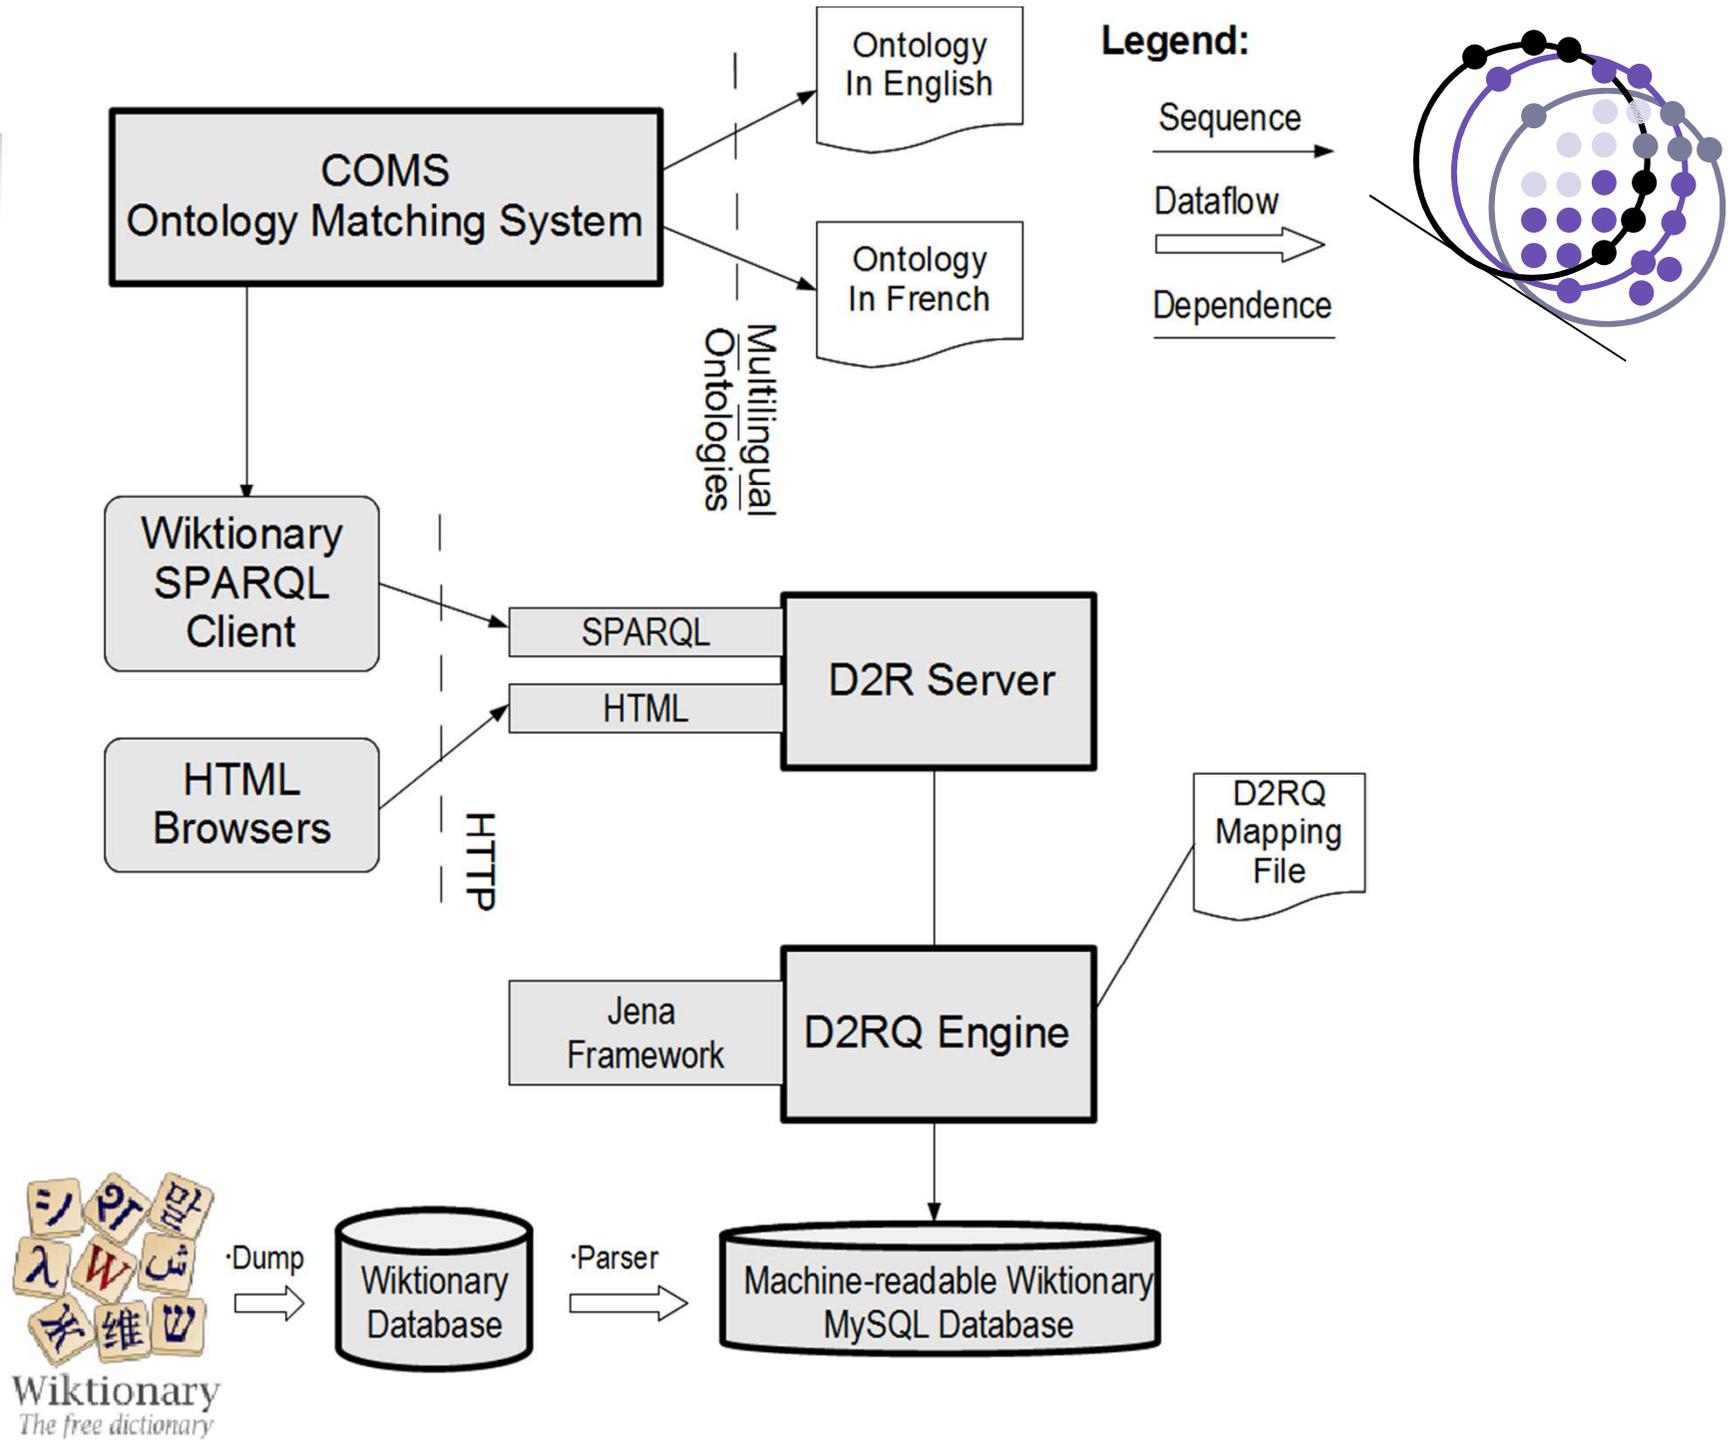
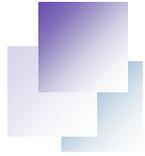
```
  ?wiki_text wikpa:wiki_text_id ?wikiTextIdDef;  
  wikpa:wiki_text_text ?definition.
```

```
}
```

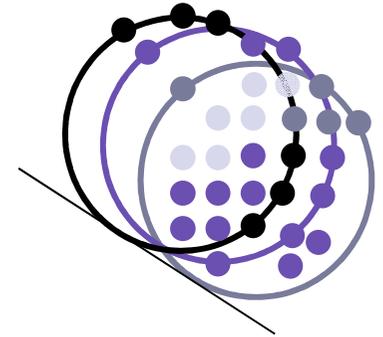
Ответ-SPARQL (список толкований слова “dog” из Английского Викисловаря)



| lang Id | pageId | lang Pos Id | mean ingId | wiki TextId Def | definition |
|---------|--------|-------------|------------|-----------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 262 | 362 | 8 | 26 | 353 | "An animal, member of the genus "Canis" (probably descended from the common wolf) that has been domesticated for thousands of years; occurs in many breeds. Scientific name: "Canis lupus familiaris"." |
| 262 | 362 | 8 | 27 | 508 | "A male dog, wolf or fox, as opposed to a bitch (a female dog, wolf or fox.)" |
| 262 | 362 | 8 | 28 | 524 | "{{derogatory}} A dull, unattractive girl or woman." |
| 262 | 362 | 8 | 29 | 528 | "{{slang}} A man." |



Эксперимент

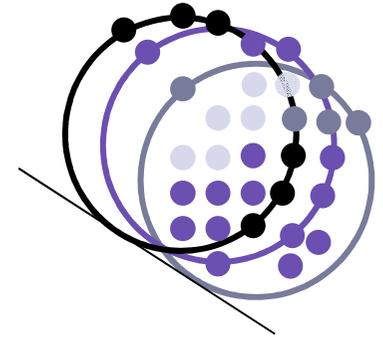


- Тестовые данные (OAEI)
 - Онтология на англ. и на фр.
 - На фр. языке: 85 классов, 97 атрибутов = 182
- Идеальное отображение - 97 элементов

| | Правильных переводов | Число элементов в отображении онтологий | Precision | Recall |
|-------------------|----------------------|-----------------------------------------|-----------|--------|
| MRD Wiktionary | 44 | 54 | 0.98 | 0.55 |
| Google | 60 | 61 | 0.98 | 0.62 |



Результаты



- SPARQL запросы к Викисловарю
 - Список толкования по слову и языку
 - Список синонимов
 - Перевод слова
(с английского на один из языков)
 - <http://code.google.com/p/wikokit/wiki/d2rqMappingSPARQL>
- Пример приложения на Java
 - создаёт SPARQL запросы и получает данные от D2RQ сервера

Спасибо за внимание!

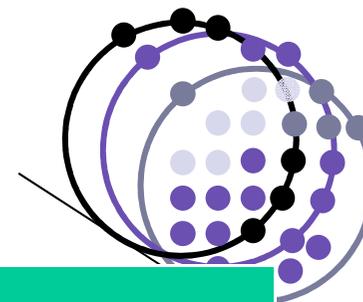
Сайт проекта:

**[http://
code.google.com/p/wikokit/](http://code.google.com/p/wikokit/)**





Машинно-читаемый Викисловарь (MRD): Синонимы



| | Викисловарь* | MRD |
|-----------------------------------------|---------------------|----------------|
| Словарных статей | 2 651 524 | 2 149 177 |
| Число языков | | 288 |
| Число языков (>10 000 словарных статей) | | 26 |
| Число языков с парадигм. отношен.** | ? | 235 |
| Языков (> 1 000 отн.) | ? | 26 |
| Число сем. отношений | ? | 220 211 |
| Формат данных | Разметка Wiki / XML | Реляционная БД |
| Противоречия и ошибки ввода данных | Есть | Нет |

*Английский Викисловарь, дампы от 18 июня 2011 г.

** Парадигматические (семантические) отношения – синонимы, антонимы, гиперонимы...



Схема отображения онтологий

