

Графы знаний

Лекция 5 - Интеграция данных в графы

М. Галкин, Д. Муромцев

Сегодня

1. Introduction
2. Представление знаний в графах - RDF & RDFS & OWL
3. Хранение знаний в графах - SPARQL & Graph Databases
4. Однородность знаний - RDF* & Wikidata & SHACL & ShEx
- 5. Интеграция данных в графы знаний - Semantic Data Integration**
6. Введение в теорию графов - Graph Theory Intro
7. Векторные представления графов - Knowledge Graph Embeddings
8. Машинное обучение на графах - Graph Neural Networks & KGs
9. Некоторые применения - Question Answering & Query Embedding

Содержание

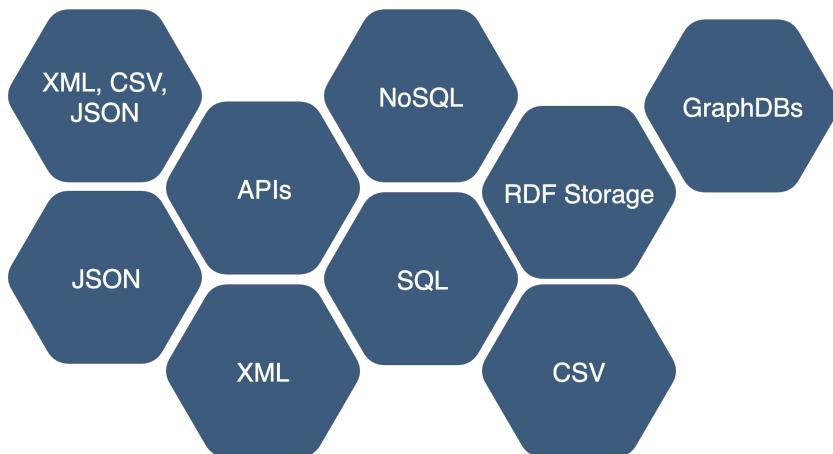
- **Способы интеграции данных в графы**
- Semantic Data Integration
 - Global-as-View
 - Local-as-View
- Физическая интеграция ETL
 - R2ML
 - RML
- Виртуальная интеграция
 - Архитектура Mediator-Wrapper
 - Федеративные запросы
 - SPARQL 2 SQL

Как строить графы знаний

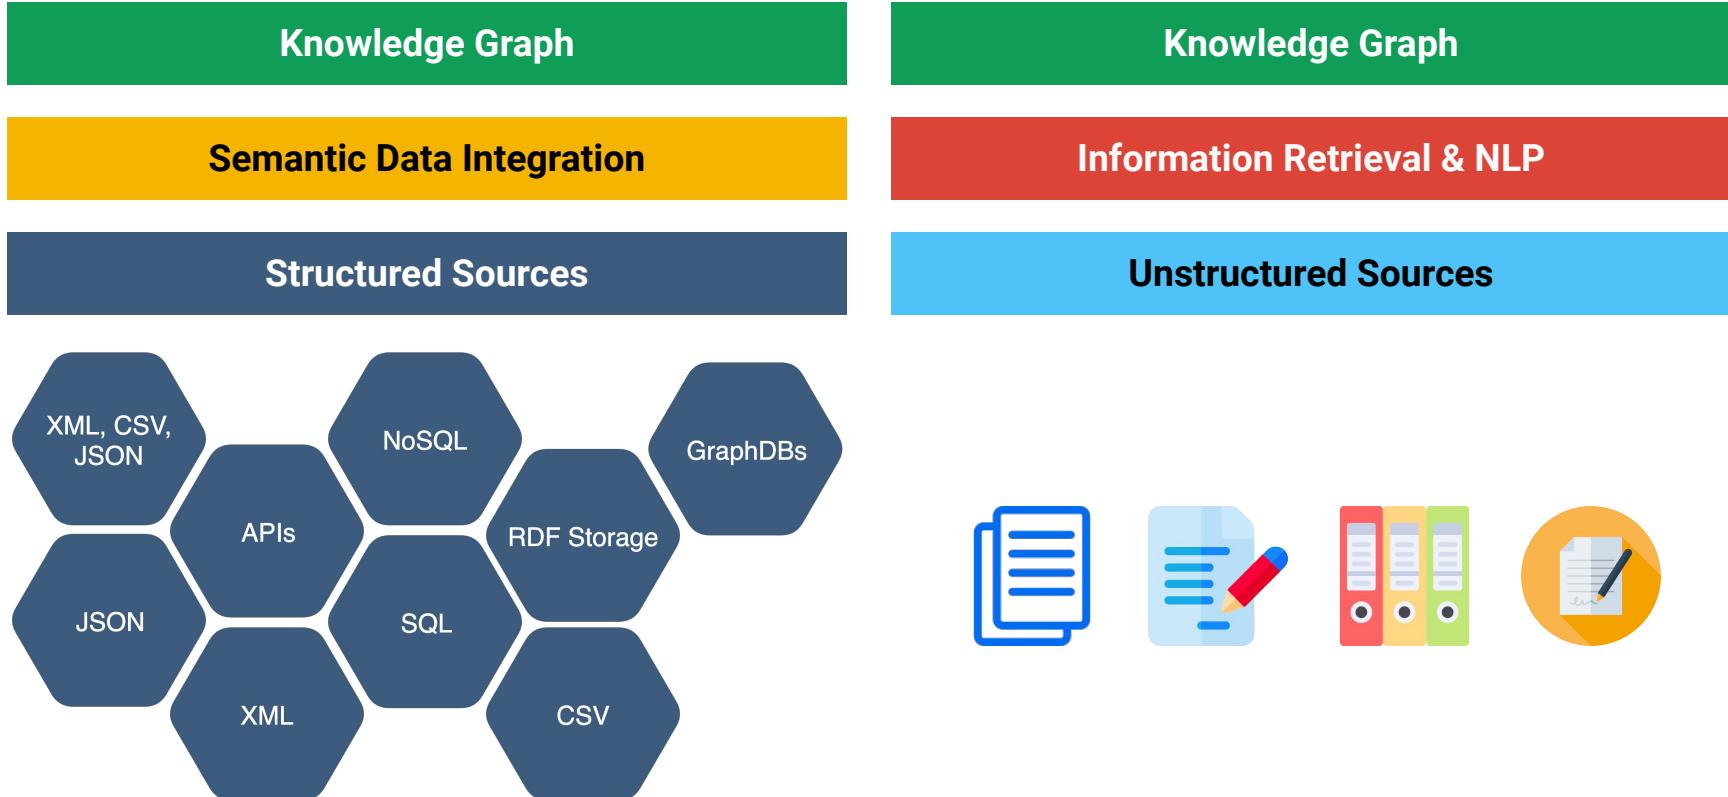
Knowledge Graph

Semantic Data Integration

Structured Sources



Как строить графы знаний



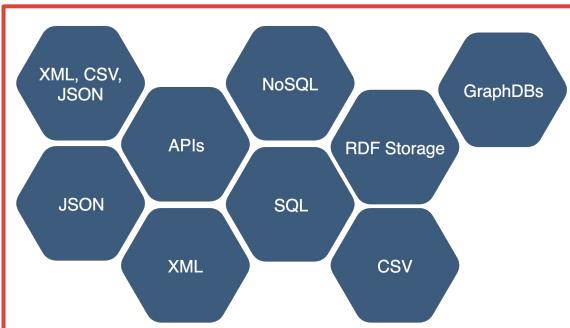
Semantic Data Integration

Knowledge Graph

Semantic Data Integration

Structured Sources

- Неоднородность форматов
- Семантическая неоднородность
- Распределенность данных
- Неоднородность именования
- Неоднозначность и эволюция данных

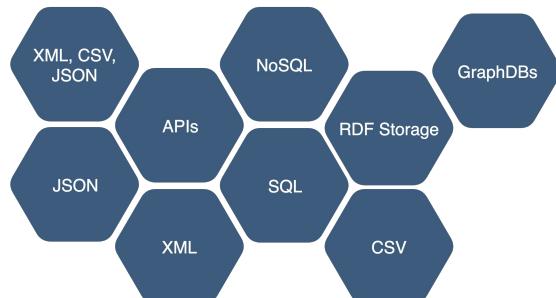


Semantic Data Integration

Knowledge Graph

Semantic Data Integration

Structured Sources



- Неоднородность форматов
- **Семантическая неоднородность**
- Распределенность данных
- Неоднородность именования
- Неоднозначность и эволюция данных

Люди

Животные

Артисты

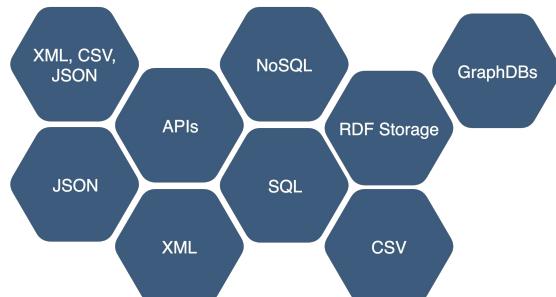
Кошки

Semantic Data Integration

Knowledge Graph

Semantic Data Integration

Structured Sources



- Неоднородность форматов
- Семантическая неоднородность
- **Распределенность данных**
- Неоднородность именования
- Неоднозначность и эволюция данных

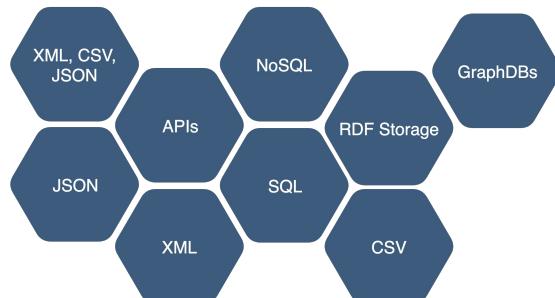


Semantic Data Integration

Knowledge Graph

Semantic Data Integration

Structured Sources



- Неоднородность форматов
- Семантическая неоднородность
- Распределенность данных
- **Неоднородность именования**
- Неоднозначность и эволюция данных

“Кронверский, 49”

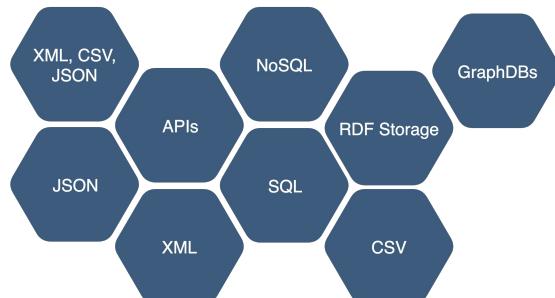
“Кронверский пр-кт, д. 49”

Semantic Data Integration

Knowledge Graph

Semantic Data Integration

Structured Sources



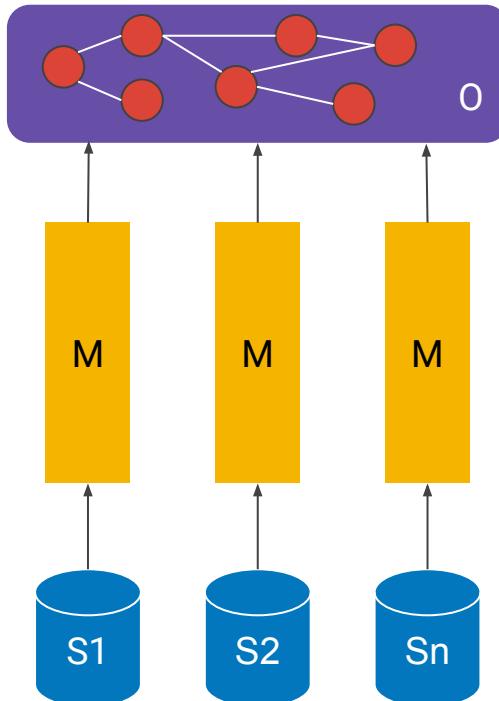
- Неоднородность форматов
- Семантическая неоднородность
- Распределенность данных
- Неоднородность именования
- **Неоднозначность и эволюция данных**

вчера	Астана
сегодня	Нурсултан

Содержание

- Способы интеграции данных в графы
- **Semantic Data Integration**
 - Global-as-View
 - Local-as-View
- Физическая интеграция ETL
 - R2ML
 - RML
- Виртуальная интеграция
 - Архитектура Mediator-Wrapper
 - Федеративные запросы
 - SPARQL 2 SQL

Semantic Data Integration



Integration System

$$IS = \langle O, S, M \rangle$$

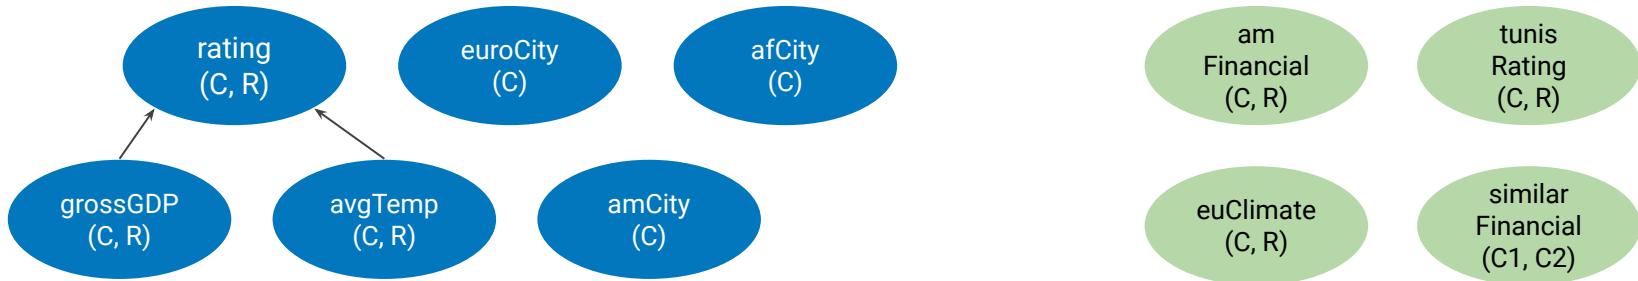
O - множество концептов в общей схеме

S - множество источников данных

M - множество отображений (маппингов)

- Global-as-View
- Local-as-View
- Global-and-Local-as-View

Semantic Data Integration



grossGDP rdf:type rdf:Property .
avgTemp rdf:type rdf:Property .
rating rdf:type rdf:Property .
grossGDP rdfs:subPropertyOf rating .
avgTemp rdfs:subPropertyOf rating .
euroCity rdf:type rdfs:Class .
amCity rdf:type rdfs:Class .
afCity rdf:type rdfs:Class .

amFinancial rdf:type rdf:Property .
euClimate rdf:type rdf:Property .
tunisRating rdf:type rdf:Property .
similarFinancial rdf:type rdf:Property .

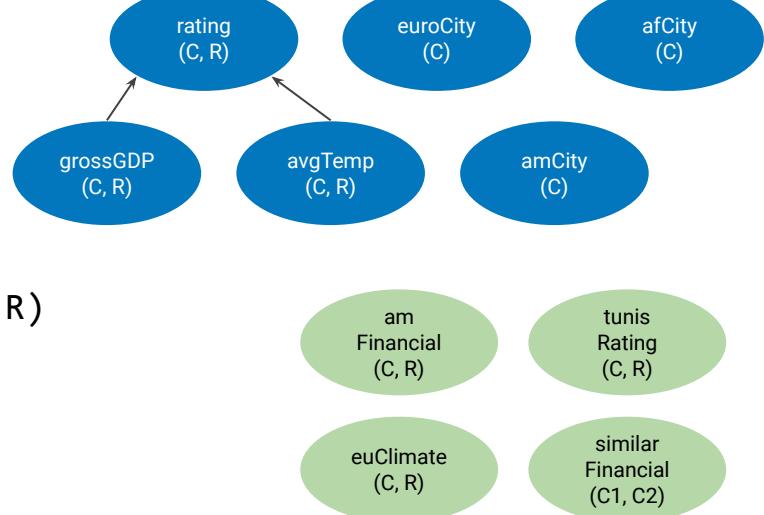
Глобальная онтология

Локальная схема источника

Semantic Data Integration - Global-as-View

Global-as-View: определение сущностей **глобальной** онтологии O в терминах **локальных** источников S

```
amCity(C)           :- amFinancial(C,R)
grossGDP(C,R)       :- amFinancial(C,R)
euroCity(C)          :- euClimate(C,R)
avgTemp(C,R)         :- euClimate(C,R)
grossGDP("Tunis",R) :- tunisRating("financial", R)
avgTemp("Tunis", R) :- tunisRating("climate", R)
afCity("Tunis")
amCity(C1)           :- similarFinancial(C1,C2)
amCity(C2)           :- similarFinancial(C1,C2)
grossGDP(C1,R)       :- similarFinancial(C1,C2), amFinancial(C2, R)
```



Semantic Data Integration - Global-as-View - Queries

Global-as-View: определение сущностей **глобальной** онтологии О в терминах **локальных** источников S

```
query(C) :- grossGDP(C,R), amCity(C)
```

```
query_1(C) :- amFinancial(C,R), similarFinancial(C,C2)
```

```
query_2(C) :- similarFinancial(C,C2), amFinancial(C2,R), similarFinancial(C1,C2)
```

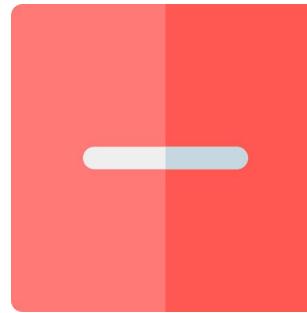
Алгоритмическая сложность переписывания GaV:

- EXPTIME - без ограничений на маппинги
- P - с ограничениями на переписывания

```
amCity(C)      :- amFinancial(C,R)
grossGDP(C,R)  :- amFinancial(C,R)
euroCity(C)    :- euClimate(C,R)
avgTemp(C,R)   :- euClimate(C,R)
grossGDP("Tunis",R) :- tunisRating("financial", R)
avgTemp("Tunis", R) :- tunisRating("climate", R)
amCity(C1)     :- similarFinancial(C1,C2)
amCity(C2)     :- similarFinancial(C1,C2)
grossGDP(C1,R) :- similarFinancial(C1,C2),
                 amFinancial(C2, R)
```

Semantic Data Integration - Global-as-View - Queries

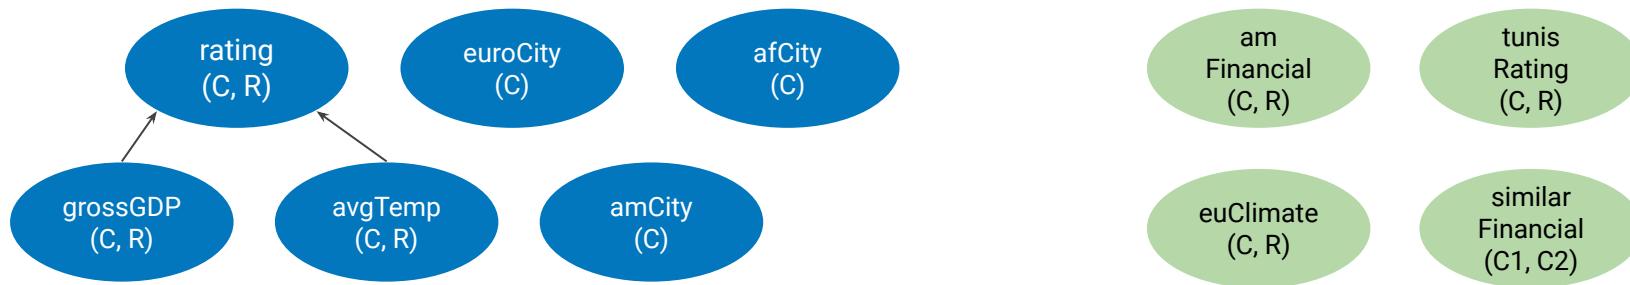
Global-as-View: определение сущностей **глобальной** онтологии O в терминах **локальных** источников S



- Полиномиальная сложность переписывания запросов при некоторых ограничениях
- Используют, когда глобальная схема меняется, а схема источников стабильная
- Если схема источников часто меняется, а глобальная схема нет

Semantic Data Integration - Local-as-View

Local-as-View: определение сущностей **локальных** источников S в терминах **глобальной** онтологии O



amFinancial(C, R)

:- amCity(C), grossGDP(C, R)

euClimate(C, R)

:- euCity(C), avgTemp(C, R)

tunisRating("financial", R)

:- afCity("Tunis"), grossGDP("Tunis", R)

tunisRating("climate", R)

:- afCity("Tunis"), avgTemp("Tunis", R)

similarFinancial(C1, C2)

:- amCity(C1), amCity(C2), grossGDP(C1, R), grossGDP(C2, R)

Semantic Data Integration - Local-as-View

Local-as-View: определение сущностей **локальных** источников S в терминах **глобальной** онтологии O

```
query(C) :- grossGDP(C,R), amCity(C)
```

```
query_1(C)      :- amFinancial(C,R)
query_2(C)      :- similarFinancial(C,C2)
```

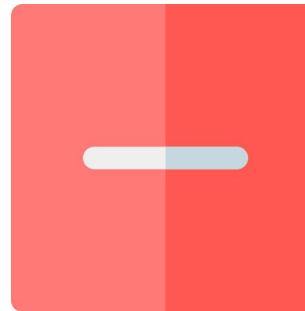
```
amFinancial(C,R)    :- amCity(C), grossGDP(C,R)
euClimate(C,R)      :- euCity(C), avgTemp(C,R)
tunisRating("financial",R) :- afCity("Tunis"), grossGDP("Tunis", R)
tunisRating("climate",R)   :- afCity("Tunis"), avgTemp("Tunis",R)
similarFinancial(C1,C2)  :-  
  amCity(C1), amCity(C2), grossGDP(C1,R), grossGDP(C2,R)
```

Алгоритмическая сложность переписывания LaV:

- NP-hard если нужно решать Query Containment

Semantic Data Integration - Local-as-View - Queries

Local-as-View: определение сущностей **локальных** источников S в терминах **глобальной** онтологии O



- Используют, когда глобальная схема постоянна, а схема источников изменяется
- Если глобальная схема часто изменяется

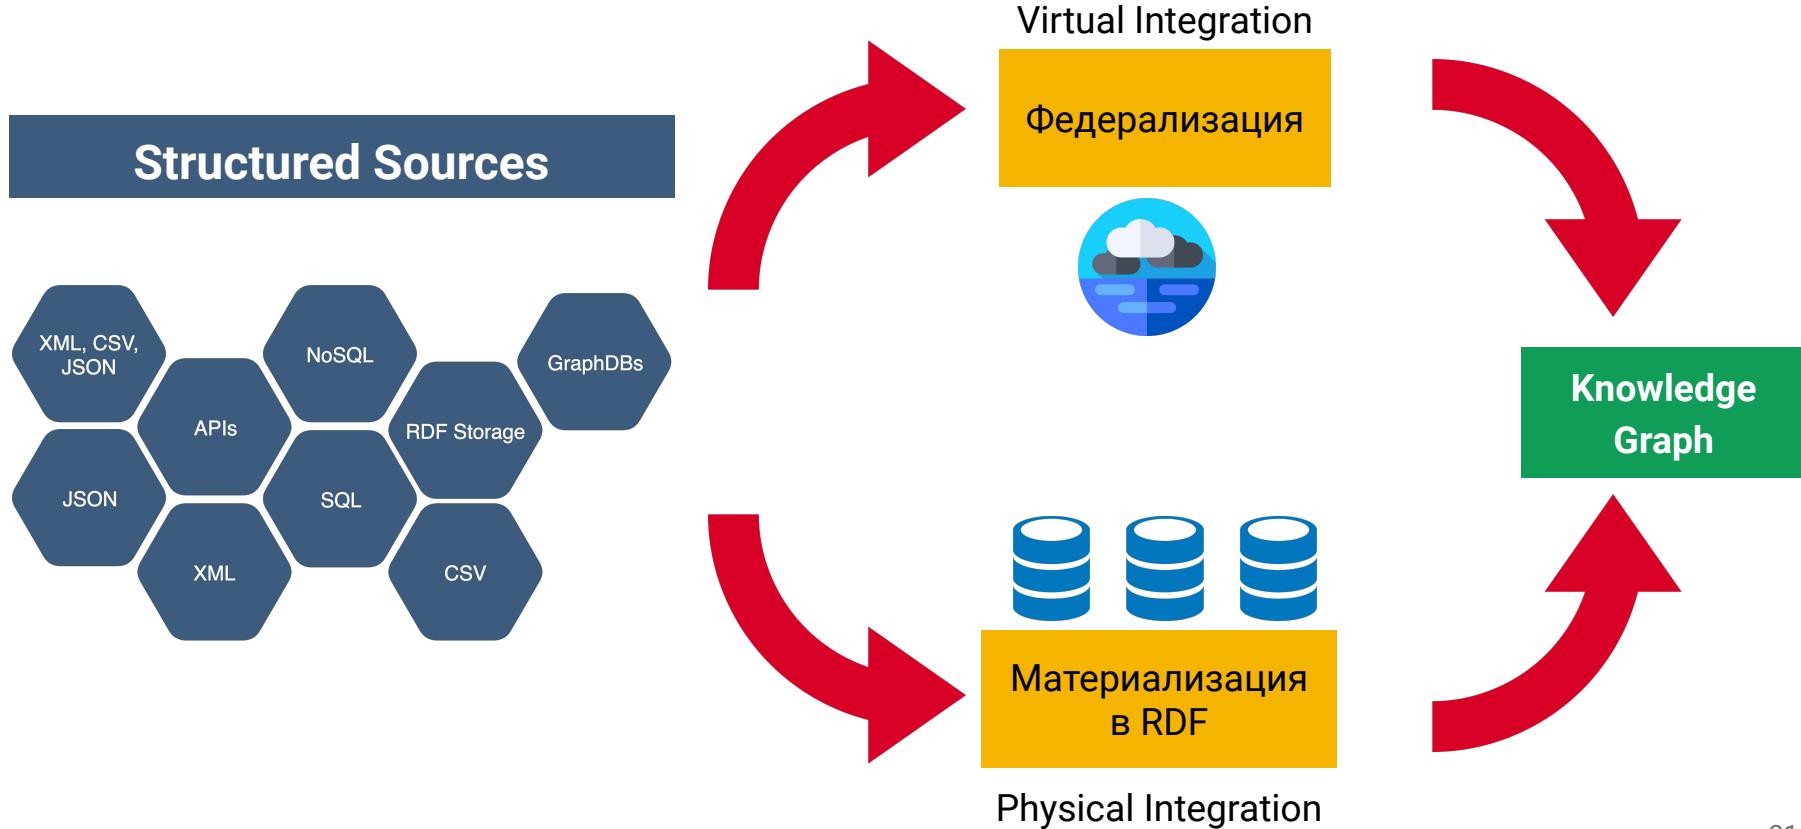
Semantic Data Integration - Global-and-Local-as-View

Global-and-Local-as-View: определение комбинации терминов **глобальной** онтологии O через комбинацию терминов **источников** S

```
amCity(C1), amCity(C2), grossGDP(C1,R), grossGDP(C2,R) :-  
    amFinancial(C1,R), similarFinancial(C1,C2)
```

Используется, когда маппинги источников S относительно просты

Semantic Data Integration



Содержание

- Способы интеграции данных в графы
- Semantic Data Integration
 - Global-as-View
 - Local-as-View
- **Физическая интеграция ETL**
 - R2ML
 - RML
- Виртуальная интеграция
 - Архитектура Mediator-Wrapper
 - Федеративные запросы
 - SPARQL 2 SQL

Physical Integration (Materialization)

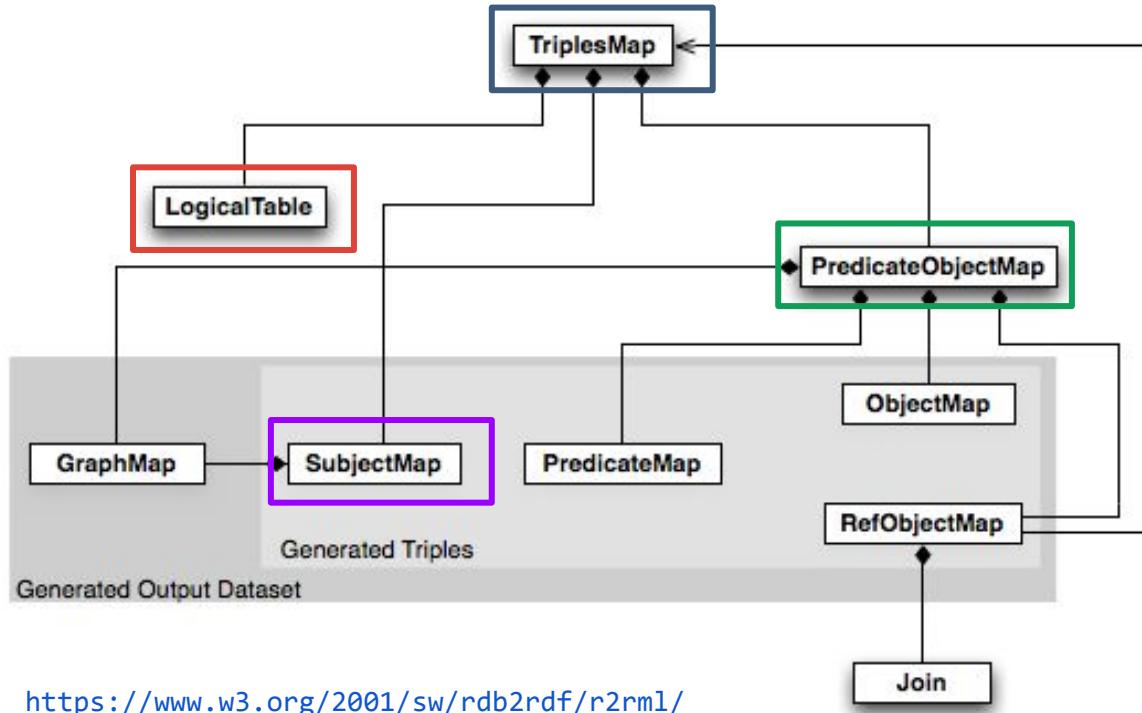


- Выделение данных для трансформации
- Подготовка и очистка датасетов
- Физическое преобразование в RDF с помощью маппингов
- Рекомендации W3C RDB2RDF
- Загрузка в единое хранилище (Data Warehouse)

Physical Integration (Materialization) - R2RML

R2RML - рекомендация W3C для создания отображений реляционных баз в RDF

rr: <http://www.w3.org/ns/r2rml#>



Logical Table - исходная база или view как результат SQL запроса

Triples Map - набор правил для преобразования строк таблиц в триплеты

Subject Map - способ задания URI генерируемой сущности

Predicate-Object Map - способ генерации предиката и объекта

Physical Integration (Materialization) - R2RML

EMP

EMPNO INTEGER PRIMARY KEY	ENAME VARCHAR (100))	JOB VARCHAR (20))	DEPTNO INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO INTEGER PRIMARY KEY	DNAME VARCHAR (30)	LOC VARCHAR (100)
10	APP SERVER	NEW YORK

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

@prefix rr: <http://www.w3.org/ns/r2rml#>.

@prefix ex: <http://example.com/ns#>.

```
<#TriplesMap1>
  rr:logicalTable [ rr:tableName "EMP" ];
  rr:subjectMap [
    rr:template "http://data.example.com/employee/{EMPNO}";
    rr:class ex:Employee;
  ];
  rr:predicateObjectMap [
    rr:predicate ex:name;
    rr:objectMap [ rr:column "ENAME" ];
  ].
```

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

@prefix rr: <http://www.w3.org/ns/r2rml#>.

@prefix ex: <http://example.com/ns#>.

```
<#TriplesMap1>
  rr:logicalTable [ rr:tableName "EMP" ];
  rr:subjectMap [
    rr:template "http://data.example.com/employee/{EMPNO}";
    rr:class ex:Employee;
  ];
  rr:predicateObjectMap [
    rr:predicate ex:name;
    rr:objectMap [ rr:column "ENAME" ];
  ].
```

```
<http://data.example.com/employee/7369> rdf:type ex:Employee.
<http://data.example.com/employee/7369> ex:name "SMITH".
```

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

```
<#DeptTableView> rr:sqlQuery """
SELECT DEPTNO, DNAME, LOC,
       (SELECT COUNT(*) FROM EMP
      WHERE EMP.DEPTNO=DEPT.DEPTNO) AS
      STAFF FROM DEPT;
""".
```

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

```
<#TriplesMap2>
  rr:logicalTable <#DeptTableView>;
  rr:subjectMap [
    rr:template "http://data.example.com/department/{DEPTNO}";
    rr:class ex:Department;
  ];
  rr:predicateObjectMap [
    rr:predicate ex:name;
    rr:objectMap [ rr:column "DNAME" ];
  ];
  rr:predicateObjectMap [
    rr:predicate ex:location;
    rr:objectMap [ rr:column "LOC" ];
  ];
  rr:predicateObjectMap [
    rr:predicate ex:staff;
    rr:objectMap [ rr:column "STAFF" ];
  ].
```

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

```
<#DeptTableView> rr:sqlQuery """
SELECT DEPTNO, DNAME, LOC,
       (SELECT COUNT(*) FROM EMP
      WHERE EMP.DEPTNO=DEPT.DEPTNO) AS
      STAFF FROM DEPT;
""".
```

```
<http://data.example.com/department/10> rdf:type ex:Department.
<http://data.example.com/department/10> ex:name "APP SERVER".
<http://data.example.com/department/10> ex:location "NEW YORK".
<http://data.example.com/department/10> ex:staff 1.
```

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

```
<#TriplesMap1>
  rr:predicateObjectMap [
    rr:predicate ex:department;
    rr:objectMap [
      rr:parentTriplesMap <#TriplesMap2>;
      rr:joinCondition [
        rr:child "DEPTNO";
        rr:parent "DEPTNO";
      ];
    ];
  ].
```

```
<http://data.example.com/employee/7369> ex:department <http://data.example.com/department/10>.
```

Physical Integration (Materialization) - R2RML

EMP

EMPNO	ENAME	JOB	DEPTNO
INTEGER PRIMARY KEY	VARCHAR(100)	VARCHAR(20)	INTEGER REFERENCES DEPT (DEPTNO)
7369	SMITH	CLERK	10

DEPT

DEPTNO	DNAME	LOC
INTEGER PRIMARY KEY	VARCHAR(30)	VARCHAR(100)
10	APP SERVER	NEW YORK

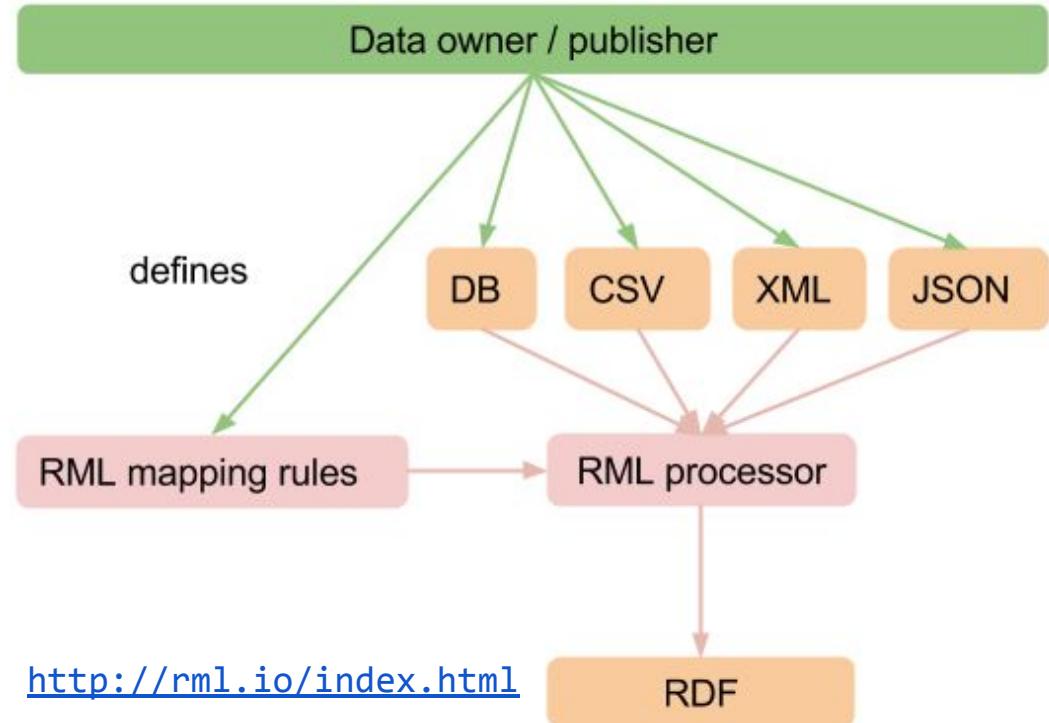
```
<#TriplesMap1>
rr:logicalTable [ rr:sqlQuery """
    SELECT EMP.* , (CASE JOB
        WHEN 'CLERK' THEN 'general-office'
        WHEN 'NIGHTGUARD' THEN 'security'
        WHEN 'ENGINEER' THEN 'engineering'
    END) ROLE FROM EMP """;
];
rr:subjectMap [
    rr:template "http://data.example.com/employee/{EMPNO}";
];
rr:predicateObjectMap [
    rr:predicate ex:role;
    rr:objectMap [ rr:template "http://data.example.com/roles/{ROLE}" ];
].

```

```
<http://data.example.com/employee/7369> ex:role <http://data.example.com/roles/general-office>.
```

Physical Integration (Materialization) - RML

RML (RDF Mapping Language) - надмножество R2RML, поддерживающее CSV, JSON, XML
rr: <http://www.w3.org/ns/r2rml#>

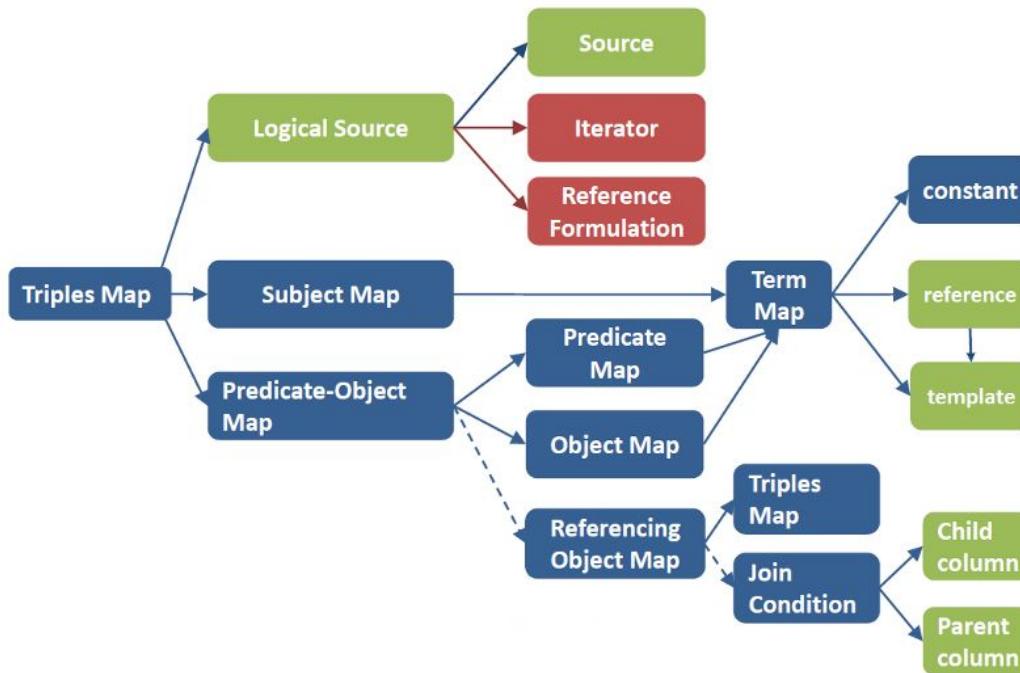


RML содержит:

- Процессор правил
- GUI
- Валидатор

Physical Integration (Materialization) - RML

RML (RDF Mapping Language) - надмножество R2RML, поддерживающее CSV, JSON, XML
rr: <http://www.w3.org/ns/r2rml#>



Logical Source теперь состоит из трех частей:

Source - ссылка на источник

Iterator - итератор по источнику

Reference Formulation - формат источника

Physical Integration (Materialization) - R2RML vs RML

R2RML		RML	
Logical Table (relational database)	rr:logicalTable	Logical Source (CSV, XML, JSON,HTML, ...)	rml:logicalSource
Table Name	rr:tableName	URI (pointing to the source)	rml:source
column	rr:column	reference	rml:reference
(SQL)	rr:SQLQuery	Reference Formulation	rml:referenceFormulation
per row iteration		defined iterator	rml:iterator

Physical Integration (Materialization) - RML

CSV

id, stop, latitude, longitude
6523, 25, 50.901389, 4.484444

Physical Integration (Materialization) - RML

CSV

```
id, stop, latitude, longitude
6523, 25, 50.901389, 4.484444
```

```
<http://airport.example.com/6523>
  rdf:type transit:Stop ;
  transit:route 25 ;
  :lat 50.901389 ;
  :long 4.484444 .
```

```
<#Mapping1>
  rml:logicalSource [
    rml:source "http://www.example.com/airports.csv" ;
    rml:referenceFormulation ql:CSV
  ];
  rr:subjectMap [
    rr:template "http://airport.example.com/{id}";
    rr:class transit:Stop
  ];
  rr:predicateObjectMap [
    rr:predicate transit:route;
    rr:objectMap [
      rml:reference "stop";
      rr:datatype xsd:int ]
  ];
  rr:predicateObjectMap [
    rr:predicate :lat;
    rr:objectMap [ rml:reference "latitude" ]
  ];
].
```

Physical Integration (Materialization) - RML

JSON

```
{  
  "venue":  
  {  
    "latitude": "51.0500000",  
    "longitude": "3.7166700"  
  },  
  "location":  
  {  
    "continent": " EU",  
    "country": "BE",  
    "city": "Brussels"  
  }  
}
```

Physical Integration (Materialization) - RML

```
<#VenueMapping>
rml:logicalSource [
  rml:source "http://www.example.com/files/Venue.json";
  rml:referenceFormulation ql:JSONPath;
  rml:iterator "$"
];
rr:subjectMap [
  rr:template
"http://loc.example.com/city/{\$ .location.city}";
  rr:class schema:City
];
rr:predicateObjectMap [
  rr:predicate wgs84_pos:lat;
  rr:objectMap [
    rml:reference "$.venue.latitude"
  ]
];
].
```

JSON

```
{
  "venue": {
    "latitude": "51.0500000",
    "longitude": "3.7166700"
  },
  "location": {
    "continent": " EU",
    "country": "BE",
    "city": "Brussels"
  }
}
```

Physical Integration (Materialization) - RML

```
<#VenueMapping>
rml:logicalSource [
  rml:source "http://www.example.com/files/Venue.json";
  rml:referenceFormulation ql:JSONPath;
  rml:iterator "$"
];
rr:subjectMap [
  rr:template
"http://loc.example.com/city/{$ .location.city}";
  rr:class schema:City
];
rr:predicateObjectMap [
  rr:predicate wgs84_pos:lat;
  rr:objectMap [
    rml:reference "$.venue.latitude"
  ]
];
].
```

JSON

```
{
  "venue": {
    "latitude": "51.0500000",
    "longitude": "3.7166700"
  },
  "location": {
    "continent": " EU",
    "country": "BE",
    "city": "Brussels"
  }
}
```

```
<http://loc.example.com/city/Brussels> rdf:type schema:City ;
  wgs84_pos:lat "50.901389" ;
  wgs84_pos:long "4.484444" ;
  gn:countryCode "BE".
```

Physical Integration (Materialization) - Tools - Karma

Karma - платформа для интеграции данных из CSV, XML, JSON, RDB, HTML. Есть GUI !

<https://github.com/usc-isi-i2/Web-Karma>

The screenshot shows the Karma platform's visual mapping interface. At the top, two entities are defined: 'Person1' and 'Class1'. Below them, a table of data is shown with columns: artist, birthDeath, creditLine, dimensions, title, sitters, and sourceURL. A mapping is being established between 'Person1' and 'Class1'. The 'name' field of 'Person1' is mapped to the 'name' field of 'Class1'. The 'sitter' field under 'sitters' is highlighted in yellow, indicating it is the current target for mapping. Below the table, specific data rows are displayed: Frishmuth, Harriet Whitney; 1880-1980; Gift of the Friends of American Art; H: 61 in.; Joy of the Waters; Henry Lancom Abbott; and a URL.

	artist	birthDeath	creditLine	dimensions	title	sitters	sourceURL
Frishmuth, Harriet Whitney	1880-1980	Gift of the Friends of American Art	H: 61 in.	Joy of the Waters	Henry Lancom Abbott	http://www.ima waters-frishmuh harriet-whitney	

- Визуальная разработка маппингов
- Собственные функции преобразования данных на Python
- Может собирать данные с HTML
- RML-совместимый формат маппингов

Physical Integration (Materialization) - OpenRefine

OpenRefine - инструмент для очищения, трансформации и обогащения табличных данных.

City	Property ID	value	size
Nelson Mandela Bay	285932.54904554586	1.0001765946811945	
Ekurhuleni	744636.2252805027	1.0000385841139363	
Tshwane	993132.4607927072	1.0000816228199126	
Cape Town	707006.1818748101	1.0001098744934072	
Ekurhuleni	931555.8733753279	1.0000623827874149	
eThekweni	308262.77349514066	1.0000589414220307	
Manguang	416583.8690035777	1.0001874125377317	
Ekurhuleni	4464	97047.55142486499	1.0000880263330981
Manguang	9691	326418.033482887	1.000139418211963
Ekurhuleni	1062	276804.1803020492	1.0002632556584619
Tshwane	8495	686130.1950057426	1.0001047503245464
Nelson Mandela Bay	3020	681660.018777077	1.0000770240302421
Ekurhuleni	3851	261423.7935685022	1.0001542876718479
Nelson Mandela Bay	6749	969502.7358824114	1.0000823788087374
Manguang	9120	508610.05339258816	1.0001924801125508
eThekweni	3511	926439.7098113969	1.0000561478145276
Tshwane	4636	577570.4919823891	1.0001503578201196
Tshwane	8843	264644.9428429294	1.000327946108683
Ekurhuleni	8442	705686.4603837691	1.0000787529042607
Johannesburg	9369	805632.3304666772	1.000046971055092
Johannesburg	4563	148092.17375155658	1.000336954092032
Nelson Mandela Bay	9813	483369.78910822206	1.0000523653397777

- LOD Refine - расширение для экспорта в RDF

<http://openrefine.org/>

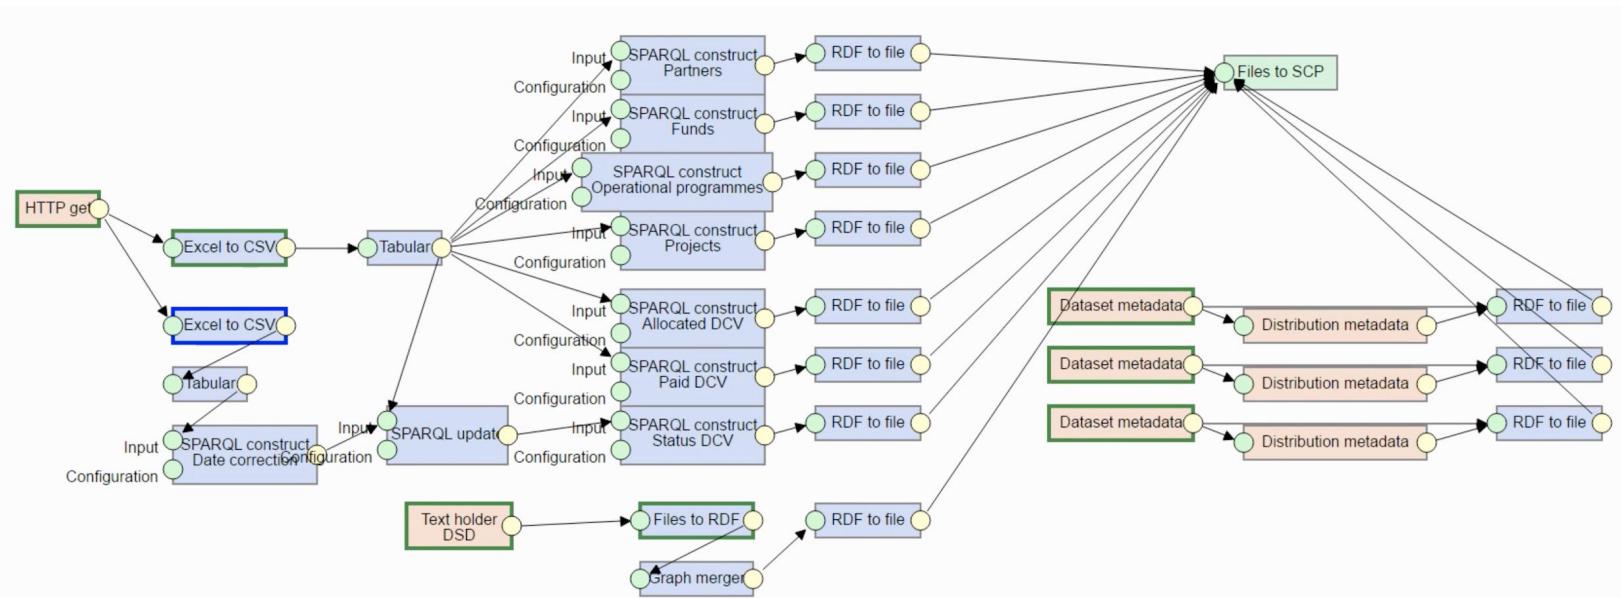
<https://github.com/sparkica/LODRefine>

Physical Integration (Materialization) - LinkedPipes

LinkedPipes - инструмент для разработки и выполнения ETL сценариев (пайплайнов).

- GUI для разработки пайплайнов
- Готовые компоненты для стандартных кейсов
- Кастомизированные компоненты

<https://linkedpipes.com/>



Physical Integration (Materialization) - SPARQL Generate

SPARQL-Generate включает маппинги прямо в SPARQL запрос

- Можно экспортить готовый RDF сразу HDT
- Можно обрабатывать текст (regexp)
- Расширение SPARQL 1.1

<https://ci.mines-stetienne.fr/sparql-generate/>

Queries Copy URL to share this setting

Links to the documentation of [iterator functions](#) and [binding functions](#).

Default query

```
6
7 GENERATE {
8
9 GENERATE {
10   <store/{?store}> ex:totalAmount ?{ sum("{?amount}"^^xsd:decimal ) } .
11 } GROUP BY ?store .
12
13 GENERATE {
14   <statistics> ex:perDay LIST( ?bnode ) .
15   ?bnode ex:averageAmount ?{ avg("{?amount}"^^xsd:decimal ) } ;
16     ex:date ?date
17 } WHERE {
18 } GROUP BY ?date
19 ORDER BY ?date
20 LIMIT 10
21 EXPRESSIONS (fun:bnode(str(?date)) AS ?bnode) .
```

Run Query

run automatically return stream debug Template

Result

```
6
7 <http://example.com/store/78>
8   ex:totalAmount 4682.83 .
9
10 <http://example.com/store/31>
11   ex:totalAmount 2532.70 .
12
13 <http://example.com/store/72>
14   ex:totalAmount 3583.27 .
15
16 <http://example.com/store/44>
17   ex:totalAmount 4524.08 .
18
19 <http://example.com/store/16>
20   ex:totalAmount 4540.59 .
```

Содержание

- Способы интеграции данных в графы
- Semantic Data Integration
 - Global-as-View
 - Local-as-View
- Физическая интеграция ETL
 - R2ML
 - RML
- **Виртуальная интеграция**
 - Архитектура Mediator-Wrapper
 - Федеративные запросы
 - SPARQL 2 SQL

Virtual Integration

Когда материализация не
подходит:

- Слишком большой объем
данных
- Нет доступа к исходным
данным, только через API
- Данные и источники часто
меняются -> преобразование
не выгодно

Virtual Integration

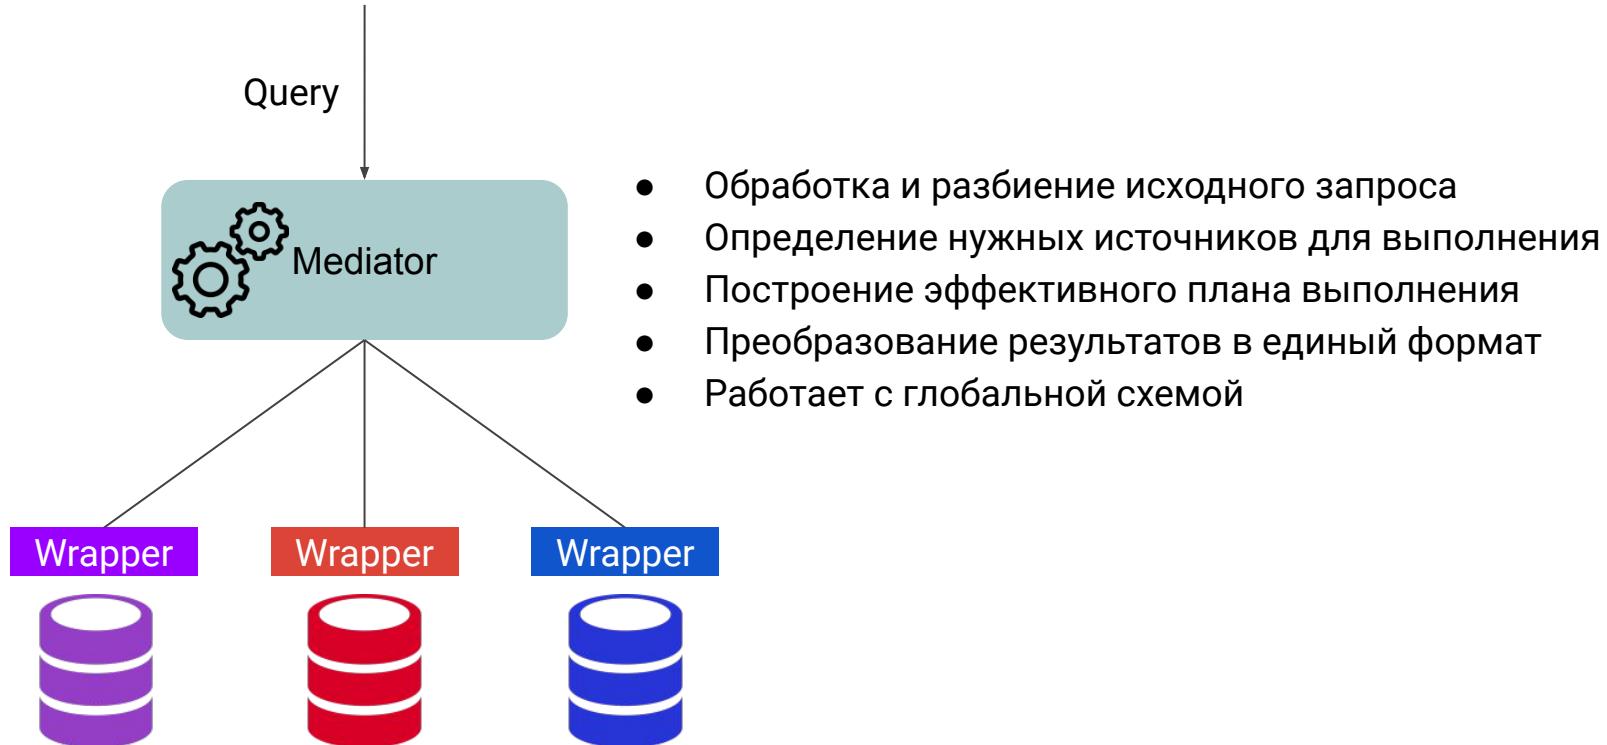
Когда материализация не
подходит:

- Слишком большой объем
данных
- Нет доступа к исходным
данным, только через API
- Данные и источники часто
меняются -> преобразование
не выгодно

Виртуальная интеграция

- Создание единой логической
схемы источников
- Единый язык запросов
- Источники опрашиваются в
нативных форматах
- Запросы переписываются на
лету

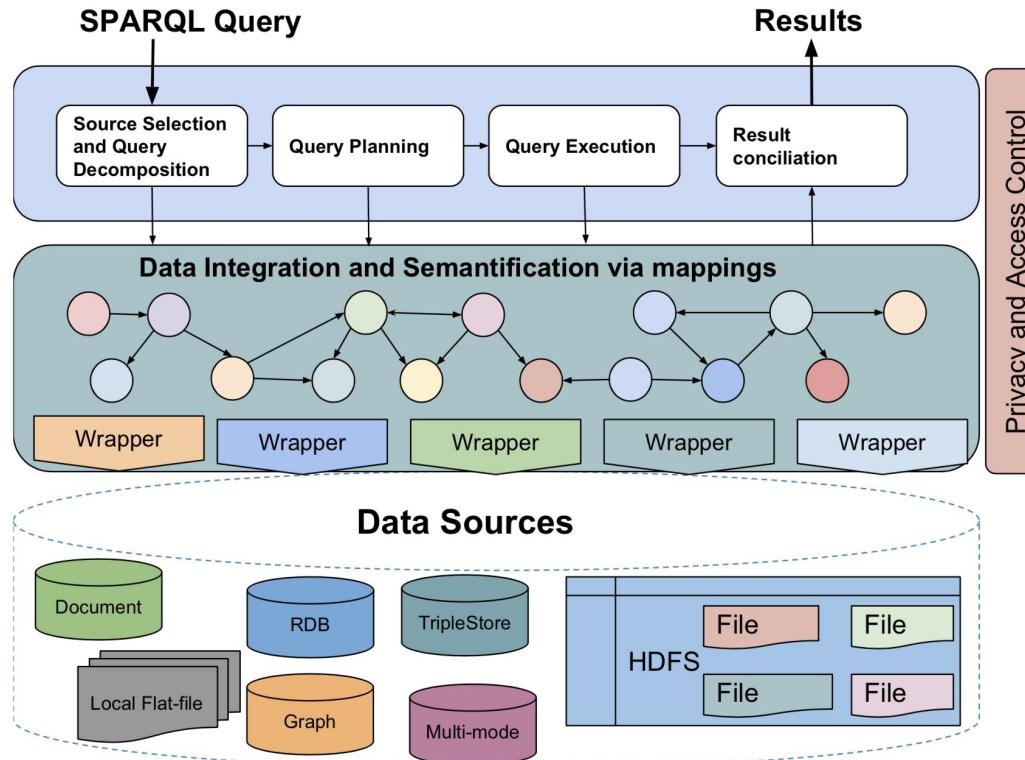
Virtual Integration - Mediator-Wrapper



Virtual Integration - Mediator-Wrapper



Virtual Integration - Semantic Data Lake



SPARQL как универсальный язык

Стадии обработки запроса

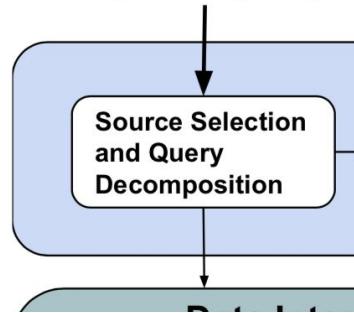
Единое логическое представление источников в Data Lake

Wrapper на каждый формат источника

Data Lake вместо Data Warehouse

Virtual Integration - Federated Querying

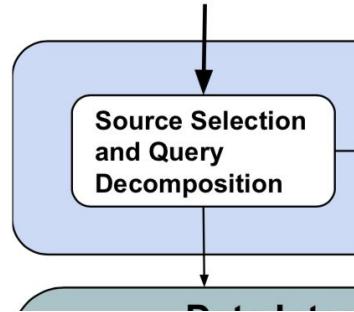
```
SELECT DISTINCT ?s WHERE {  
  ?s foaf:page      ?page .  
  ?s owl:sameAs     ?sameas .  
  ?s geonames:inCountry  ?inCountry . }
```



Virtual Integration - Federated Querying

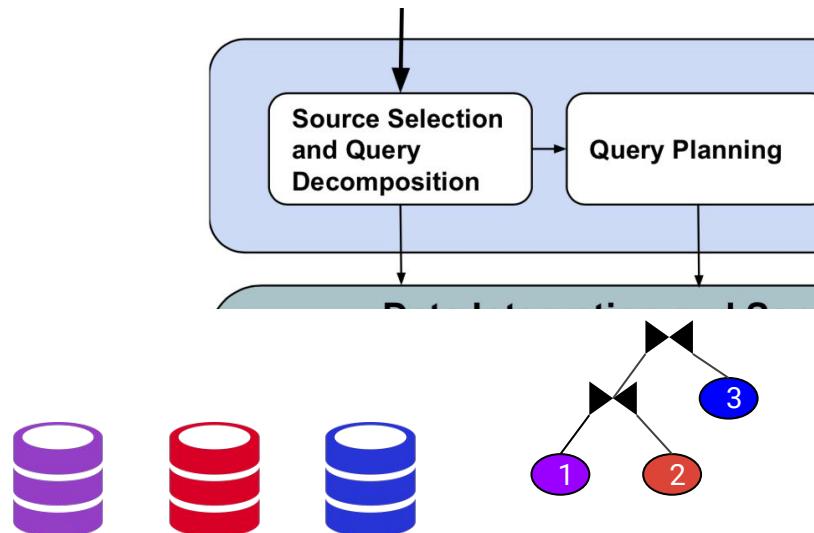
```
SELECT DISTINCT ?s WHERE {  
1 ?s foaf:page      ?page .  
2 ?s owl:sameAs     ?sameas .  
3 ?s geonames:inCountry  ?inCountry . }
```

1
2
3



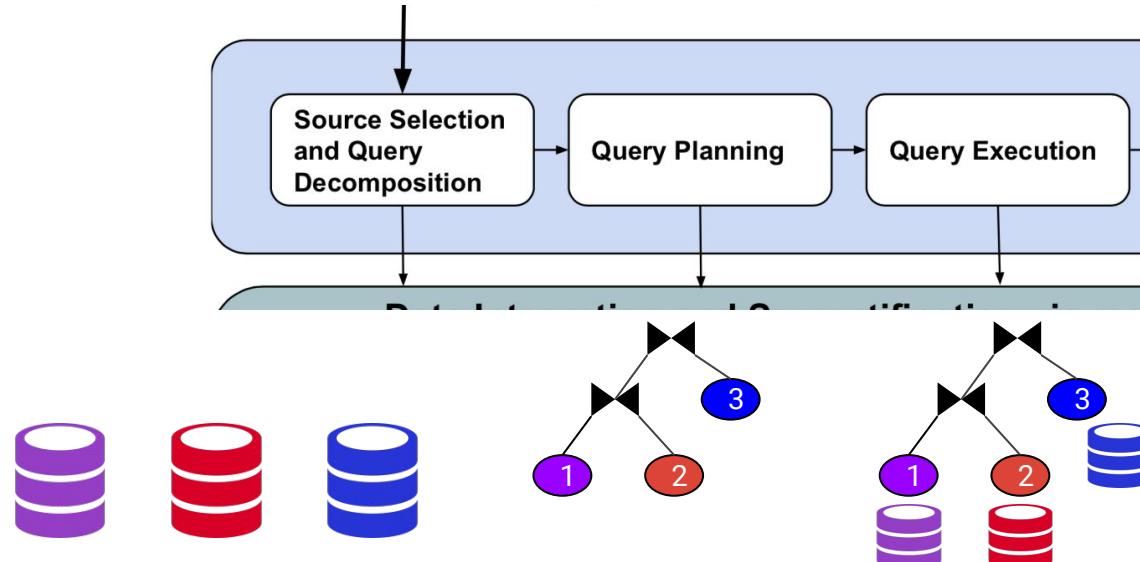
Virtual Integration - Federated Querying

```
SELECT DISTINCT ?s WHERE {  
  1 ?s foaf:page      ?page .  
  2 ?s owl:sameAs     ?sameas .  
  3 ?s geonames:inCountry ?inCountry . }
```



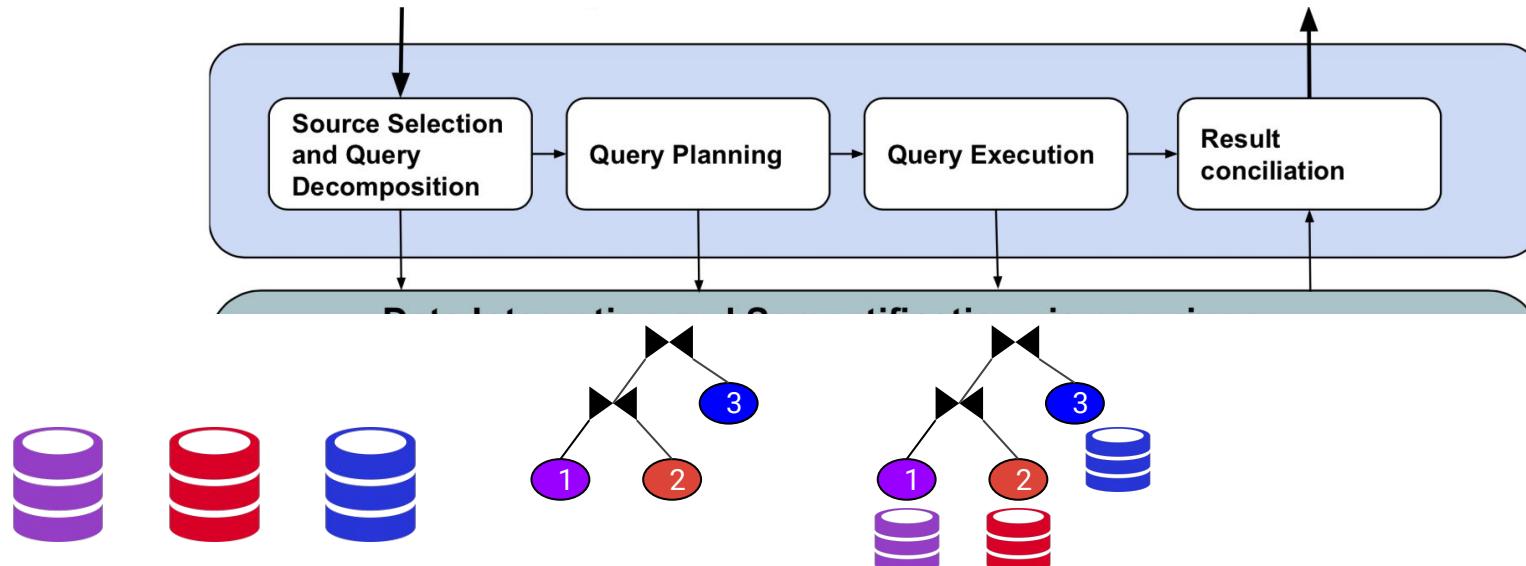
Virtual Integration - Federated Querying

```
SELECT DISTINCT ?s WHERE {  
  1 ?s foaf:page      ?page .  
  2 ?s owl:sameAs     ?sameas .  
  3 ?s geonames:inCountry ?inCountry . }
```



Virtual Integration - Federated Querying

```
SELECT DISTINCT ?s WHERE {  
  1 ?s foaf:page      ?page .  
  2 ?s owl:sameAs     ?sameas .  
  3 ?s geonames:inCountry ?inCountry . }
```



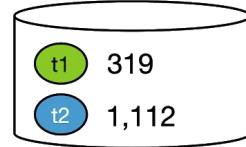
Virtual Integration - Query Decomposition & Source Selection

Задача - определить релевантные источники, содержащие искомые triple pattern и максимизировать полноту возвращаемых значений

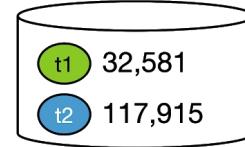
SELECT DISTINCT ?s WHERE {

t1 ?s foaf:page ?page .
t2 ?s owl:sameAs ?sameas .
t3 ?s geonames:inCountry ?inCountry }

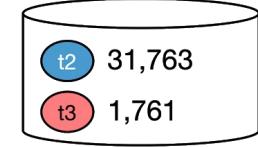
SWDF



Geonames



NYTimes



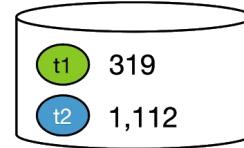
Virtual Integration - Query Decomposition & Source Selection

Задача - определить релевантные источники, содержащие искомые triple pattern и максимизировать полноту возвращаемых значений

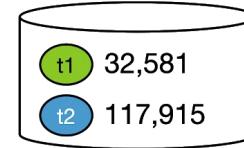
SELECT DISTINCT ?s WHERE {

?s foaf:page ?page .
 ?s owl:sameAs ?sameas .
 ?s geonames:inCountry ?inCountry }

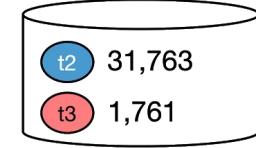
SWDF



Geonames



NYTimes



Join

triples

swdf	swdf	371
geo	geo	524
nyt	nyt	1,249
geo	geo	8
geo	nyt	19
geo	geo \cup nyt	20

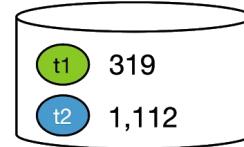
Virtual Integration - Query Decomposition & Source Selection

Задача - определить релевантные источники, содержащие искомые triple pattern и максимизировать полноту возвращаемых значений

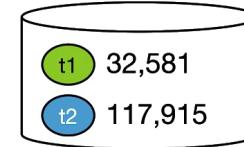
SELECT DISTINCT ?s WHERE {

t1 ?s foaf:page ?page .
t2 ?s owl:sameAs ?sameas .
t3 ?s geonames:inCountry ?inCountry }

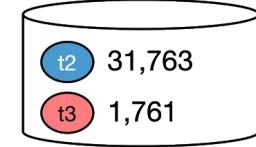
SWDF



Geonames



NYTimes



Join



triples

371



524



1,249



8



19



20

FedX

t1 @ SWDF, Geo

t2 @ SWDF, Geo, NYTimes

t3 @ NYTimes

sec 239.4

triples 20

ANAPSID SSGS

(t1, t2) @ SWDF

t3 @ NYTimes

0.338

0

ANAPSID SSGM

t1 @ SWDF, Geo

(t2, t3) @ NYTimes

88.9

19

Virtual Integration - Query Planning

Задача - создать эффективный план выполнения запроса по выбранным источникам

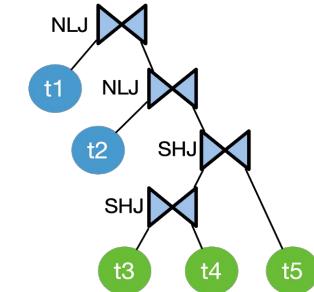
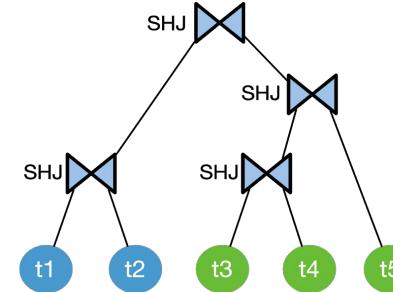
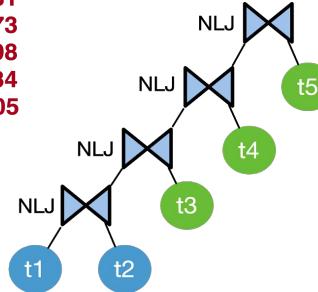
```
SELECT DISTINCT * WHERE {  
t1 ?s dct:subject ?o1. #Count: 115 259 581  
t2 ?s dbo:director ?o2. #Count: 385 773  
t3 ?s dbo:genre dbr:Concert. #Count: 98  
t4 ?s dbo:artist dbr:Ana_Gabriel. #Count: 34  
t5 ?s dbo:genre dbr:Ranchera. } #Count: 205
```

- low-selective pattern : count_max >> count_min
- high-selective pattern: count_min << count_max

Virtual Integration - Query Planning

Задача - создать эффективный план выполнения запроса по выбранным источникам

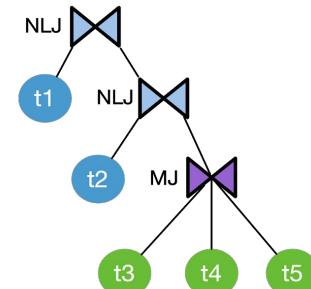
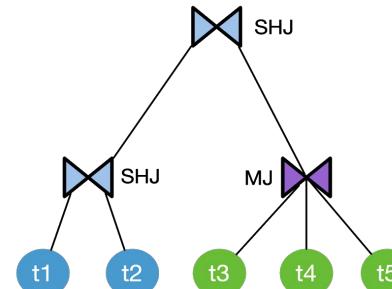
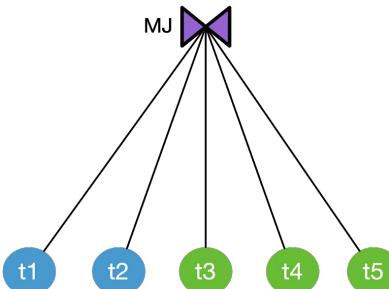
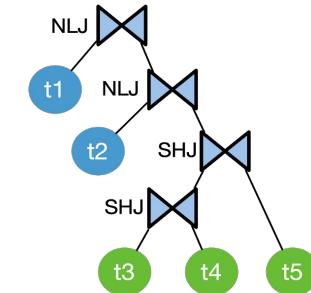
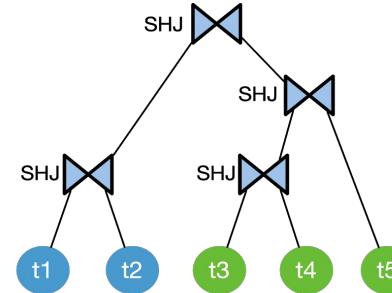
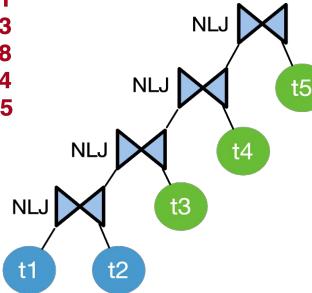
```
SELECT DISTINCT * WHERE {
  t1 ?s dct:subject ?o1. #Count: 115 259 581
  t2 ?s dbo:director ?o2. #Count: 385 773
  t3 ?s dbo:genre dbr:Concert. #Count: 98
  t4 ?s dbo:artist dbr:Ana_Gabriel. #Count: 34
  t5 ?s dbo:genre dbr:Ranchera. } #Count: 205
```



Virtual Integration - Query Planning

Задача - создать эффективный план выполнения запроса по выбранным источникам

```
SELECT DISTINCT * WHERE {
  t1 ?s dct:subject ?o1. #Count: 115 259 581
  t2 ?s dbo:director ?o2. #Count: 385 773
  t3 ?s dbo:genre dbr:Concert. #Count: 98
  t4 ?s dbo:artist dbr:Ana_Gabriel. #Count: 34
  t5 ?s dbo:genre dbr:Ranchera. } #Count: 205
```

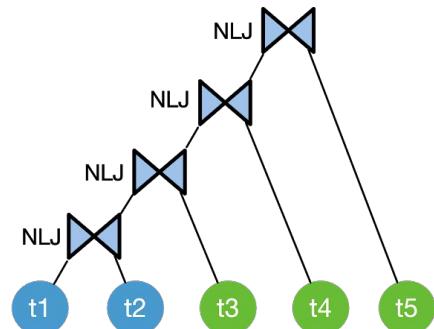


Plan	ET, ms	Results
NLJs, (b)	634	12
SHJs, (c)	timeout	0
NLJs + SHJs, (d)	243	12
MJ-only, (f)	timeout	0
MJ + SHJs, (g)	timeout	0
MJ + NLJs, (h)	195	12

Virtual Integration - Adaptive Query Execution

Задача - адаптировать план выполнения запроса к внешним воздействиям

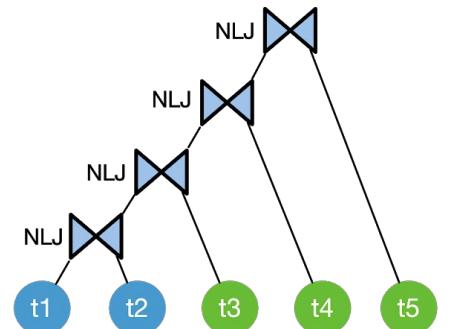
- Планы кумулятивные (результаты выдаются по мере появления, а не все сразу)
- Источники могут стать недоступными
- Сетевые задержки
- Динамическое изменение плана в процессе выполнения запроса



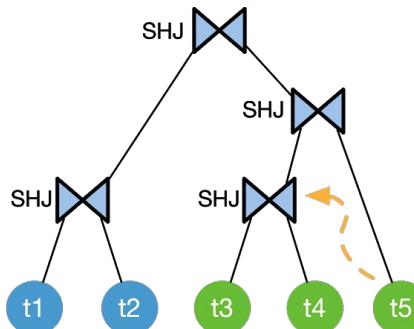
Virtual Integration - Adaptive Query Execution

Задача - адаптировать план выполнения запроса к внешним воздействиям

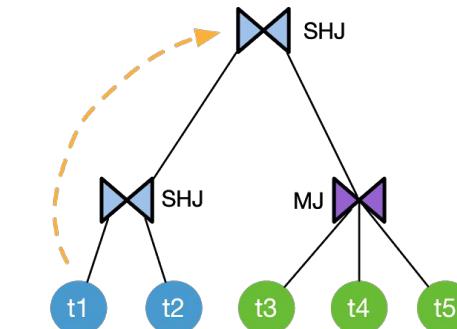
- Планы кумулятивные (результаты выдаются по мере появления, а не все сразу)
- Источники могут стать недоступными
- Сетевые задержки
- Динамическое изменение плана в процессе выполнения запроса



Изменение плана в целом



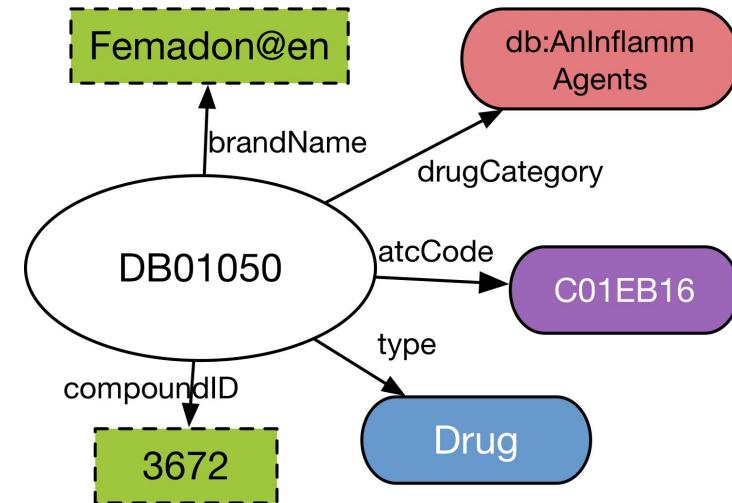
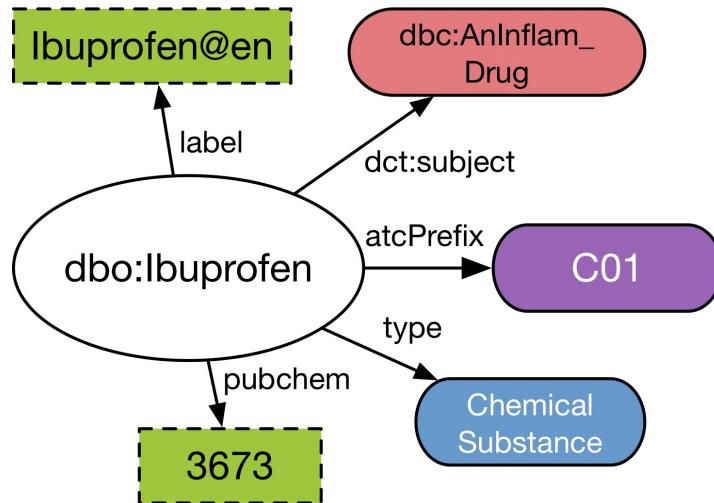
(t3, t4, t5)
Symmetric -> MJoin



Изменения порядка операторов

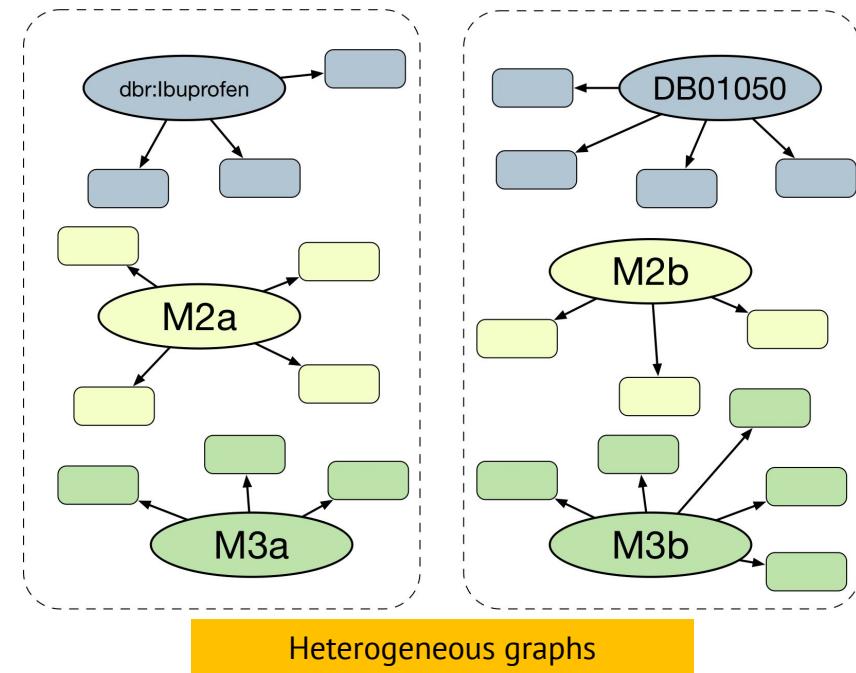
Virtual Integration - Results Reconciliation

Медиатор может выполнять вспомогательное агрегирование результатов для дедупликации



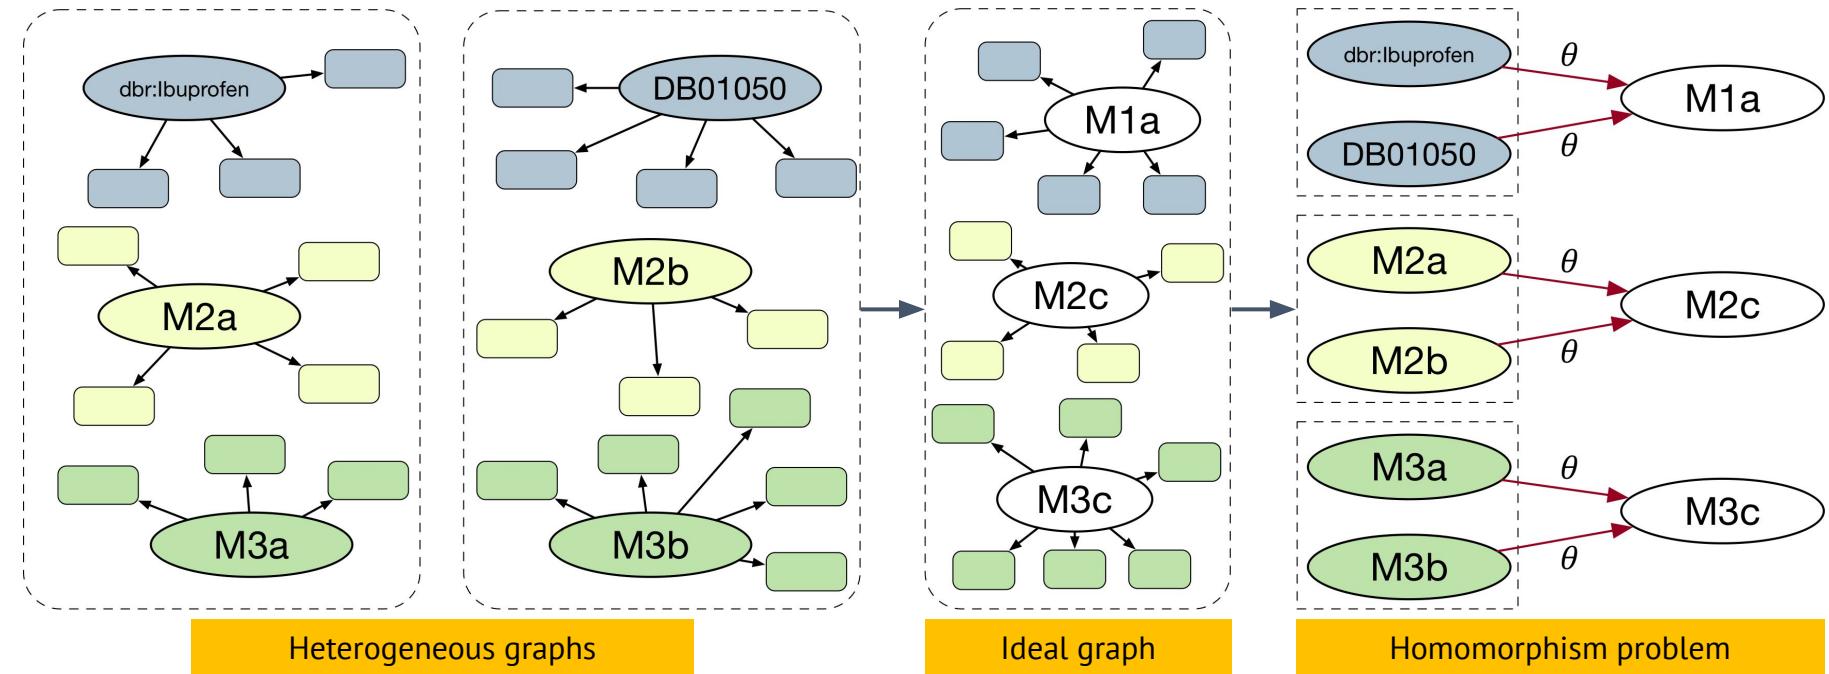
Virtual Integration - Results Reconciliation

Медиатор может выполнять вспомогательное агрегирование результатов для дедупликации

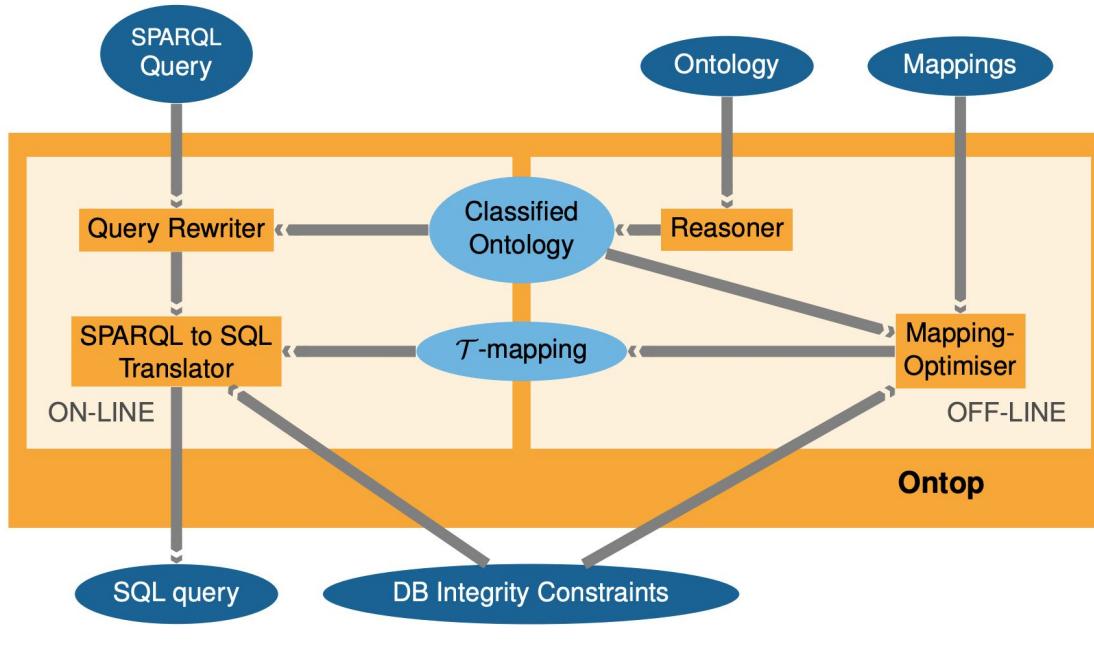


Virtual Integration - Results Reconciliation

Медиатор может выполнять вспомогательное агрегирование результатов для дедупликации



Virtual Integration - Wrappers - SPARQL 2 SQL - Ontop



- Трансляция SPARQL в SQL на лету
 - Маппинги Quest / R2RML
1. Подготовительный этап (преобразование онтологии и маппингов в τ -mappings)
 2. Исполнительный этап (SPARQL \rightarrow SQL \rightarrow JDBC \rightarrow RDF)

Virtual Integration - Wrappers - SPARQL 2 SQL - Ontop

```
SELECT ?tumor WHERE {  
    ?tumor rdf:type :Neoplasm ;  
        :hasStage :stage-IIIa .  
}
```

Virtual Integration - Wrappers - SPARQL 2 SQL - Ontop

```
SELECT ?tumor WHERE {  
    ?tumor rdf:type :Neoplasm ;  
        :hasStage :stage-IIIa .  
}
```

```
SELECT Q1.x FROM  
(( SELECT concat(":db1/neoplasm/", pid) AS x FROM tbl_patient  
    WHERE type=false OR type=true) Q1  
JOIN  
( SELECT concat(":db1/neoplasm/", pid) AS x FROM tbl_patient  
    WHERE stage = 4 ) Q2  
ON  
Q1.x = Q2.x )
```

Structural Optimizations &
Self-joins Elimination

```
SELECT concat(":db1/neoplasm/", Q.pid) AS x FROM  
(SELECT T1.pid  
    FROM tbl_patient T1 JOIN tbl_patient T2 ON T1.pid = T2.pid  
    WHERE (T1.type = false OR T1.type = true) AND T2.stage = 4  
) Q
```

```
SELECT concat(":db1/neoplasm/", Q.pid) AS x FROM  
(SELECT pid FROM tbl_patient  
    WHERE (type=false OR type=true) AND stage = 4) Q
```

Virtual Integration - Wrappers - SPARQL 2 SQL - Ontop

```
SELECT ?tumor WHERE {  
    ?tumor rdf:type :Neoplasm ;  
        :hasStage :stage-IIIa .  
}
```

```
SELECT Q1.x FROM  
(( SELECT concat(":db1/neoplasm/", pid) AS x FROM tbl_patient  
    WHERE type=false OR type=true) Q1  
JOIN  
( SELECT concat(":db1/neoplasm/", pid) AS x FROM tbl_patient  
    WHERE stage = 4 ) Q2  
ON  
Q1.x = Q2.x )
```

Structural Optimizations &
Self-joins Elimination

```
SELECT  
concat(":db1/neoplasm/", pid) AS x  
FROM tbl_patient  
WHERE  
(type=false OR type=true)  
AND stage = 4
```

```
SELECT concat(":db1/neoplasm/", Q.pid) AS x FROM  
(SELECT T1.pid  
    FROM tbl_patient T1 JOIN tbl_patient T2 ON T1.pid = T2.pid  
    WHERE (T1.type = false OR T1.type = true) AND T2.stage = 4  
) Q
```

```
SELECT concat(":db1/neoplasm/", Q.pid) AS x FROM  
(SELECT pid FROM tbl_patient  
    WHERE (type=false OR type=true) AND stage = 4) Q
```

В следующей серии

1. Introduction
2. Представление знаний в графах - RDF & RDFS & OWL
3. Хранение знаний в графах - SPARQL & Graph Databases
4. Однородность знаний - RDF* & Wikidata & SHACL & ShEx
5. Интеграция данных в графы знаний - Semantic Data Integration
- 6. Введение в теорию графов - Graph Theory Intro**
7. Векторные представления графов - Knowledge Graph Embeddings
8. Машинное обучение на графах - Graph Neural Networks & KGs
9. Некоторые применения - Question Answering & Query Embedding