Проблемы использования данных из облака LOD для обогащения контента научных баз данных и знаний

© З. В. Апанович © А. Г. Марчук
Институт систем информатики им. А.П. Ершова СО РАН,
Новосибирск
apanovich@iis.nsk.su mag@iis.nsk.su

Аннотация

В данной работе описаны проблемы, возникающие в процессе использования данных из облака LOD для обогащения контента научных баз данных и знаний и подходы к их решению. Эксперименты выполнялись при помощи набора инструментов, разработанного для упрощения анализа данных из разных наборов. В качестве тестовых примеров использовались данные открытого Архива СО РАН, и его онтология ОНС, а также различные наборы библиографических данных, структурированные при помощи онтологии AKT Reference ontology.

Введение

В связи с бурно развивающимся направлением Semantic Web и его новой ветвью LOD (Связанные Открытые Данные) в Интернете становятся доступными большие объемы информации, посвященной различным научным направлениям. Облако LOD содержит в настоящий момент более 28 миллиардов троек RDF. С одной стороны, эти данные могут быть использованы для обогащения имеющихся семантических баз данных, с другой стороны, имеющиеся базы данные могут быть также полезны для уточнения информации, хранящейся в облаке LOD.

В работе [18] предложена четырехшаговая стратегия интеграции Связанных Данных в приложения. Помимо проблем, специфических для конкретного приложения, требуется решить проблему доступа к связанным данным (1), проблему нормализации словарей (2), установления идентичности сущностей (3) и фильтрации данных (4). Способы решения этих проблем варьируют в диапазоне от полностью ручных до автоматизированных [4, 8, 10, 13, 14, 19]. При этом многие проблемы, такие, как проблема обработки данных большого объема, проблема установления соответствия между онтологиями, а также проблема объединения данных из разных наборов «еще находятся в детском состоянии» [19]. С другой стороны, проблема (1) может быть решена при помощи запросов SPARQL 1.1 [8]. Проблема (2) может быть решена как при помощи сложных запросов SPARQL 1.1. Проблема (3) может быть частично решена при помощи таких полуавтоматических инструментов, как SILK [10] или LIMES [13] совместно с использованием запросов SPARQL. Наконец, проблема (4) также может быть решена при помощи запросов SPARQL 1.1. Поскольку практически каждая из проблем может быть решена при помощи подходящего набора SPARQL-запросов, мы расширили разработанную ранее программу визуализации онтологий средствами построения SPARQL-запросов и генерации результатов как в текстовом виде, так и в виде графа. SPARQL- запросы могут быть сгенерированы также на основе нашей визуализации одной или двух онтологий. В качестве тестовых примеров использовались онтология ОНС и данные открытого Архива СО РАН [20], а также AKT Reference ontology [1], при помощи которой структурированы различные наборы библиографических данных. В работе сравнивается их структура, и обсуждается стратегия установления связей между наборами данных, описанных при помощи этих онтологий.

1 Визуализация онтологий для исследования семантических систем

В настоящий момент в ИСИ СО РАН выполняется проект, направленный на интеграцию баз данных, разработанных в ИСИ СО РАН с данными мирового сообщества. С этой целью изучаются базы данных облака Linked Open Data [4] и выясняются возможности интеграции с ними систем, разработанных в ИСИ СО РАН [20], в

Труды 15-й Всероссийской научной конференции «Электронные библиотеки: перспективные методы и технологии, электронные коллекции» — RCDL-2013, Ярославль, Россия, 14-17 октября 2013 г.

частности, научной информации из открытого архива и фотоархива СО РАН [http://soran1957.iis.nsk.su/pa2/Home/Portrait?id=c_do 1000663]. Ее основное наполнение составляют документы, посвященные различным событиям СО РАН, начиная с 1957 года. В базе имеется также структурированная информация о людях, отраженных в документах, научных организациях, и важнейших событиях в жизни СО РАН, в частности, о научных конференциях. Структура Открытого архива организована при помощи Онтологии Неспецифических Сущностей (ОНС), описанной в OWL-формате и содержащей 44 класса.

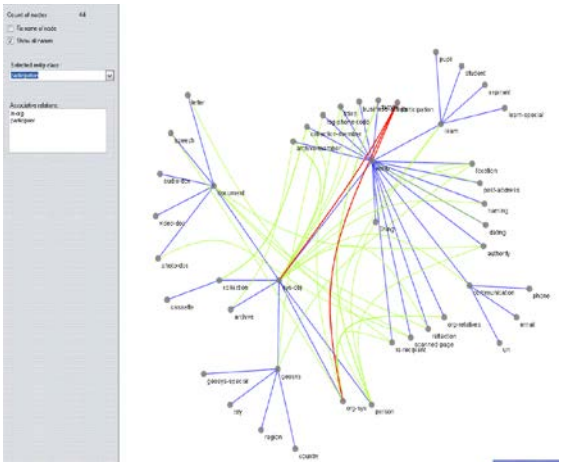

(а)

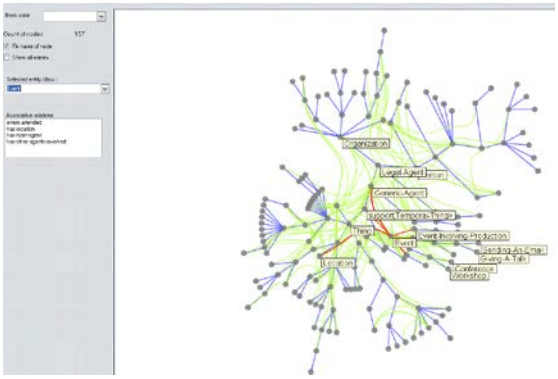

(б)

Рис. 1. (а) Классы и отношения онтологии ОНС, (б) классы и отношения AKT reference ontology.

На Рис. 1(а) показано изображение онтология ОНС открытого архива СО РАН, построенное нашей программой визуализации [21]. Прямолинейные ребра изображают таксономию, задаваемую отношениями класс-подкласс. Криволинейные ребра изображают отношения типа *owl:ObjectProperty*. При выборе одного из классов в поле “Selected entity class” на панели визуализации графа высвечиваются все отношения, описанные в онтологии как *owl:ObjectProperty*, а в нижнем поле выдается список отношений этого класса (*owl:DatatypeProperty* и *owl:ObjectProperty*). При выборе элемента этого списка соответствующие ребра высвечиваются в окне визуализации. Это свойство визуализации весьма существенно для понимания незнакомой онтологии. Например, при выборе в онтологии такого класса как *онс:participation* высвечиваются ребра, соединяющие классы *онс:person, онс: participatio*n и *онс:org-sys*. Эта визуализация демонстрирует специфическую особенность онтологии ОНС, состоящую в том, что многие сущности, обычно описываемые как отношения, в данной онтологии описаны как классы, компенсируя отсутствие атрибутов у отношений в формате RDF.

Для сравнения, на Рис. 1(б) показаны классы и отношения AKT reference ontology [1], которая в облаке LOD используется для описания многих библиографических порталов, таких как DBLP, Citeseer, ACM, IEEE и др. Часть данных этих порталов представлены в облаке Open Linked Data[5, 7]. Она содержит 157 классов.

Попытки установления соответствия между этими онтологиями при помощи одной из лучших программ выравнивания AgreementMaker [6] оказались неудачными как из-за существенных лексических и структурных различий между рассматриваемыми онтологиями, так и из-за специфических особенностей онтологии ОНС, обсуждаемых ниже. Единственное очевидное соответствие наблюдается между классами *онс:person* и *akt:Person*. Остальные связи гораздо менее очевидны. Рассмотрим, например, класс *онс:participation*. В онтологии открытого архива этот класс используется для описания фактов работы персон в различных организациях, а также фактов участия в различных мероприятиях, например, конференциях. Этот класс связан отношением *онс:participant* с классом *онс:person* и отношением *онс:in-org* с классом *онс:org-sys*. Класс *онс:org-sys* используется как для описания различных организаций, так и для описания мероприятий, например, конференций. В AKT Reference ontology эти же самые факты могут быть описаны несколькими способами. Это может быть отношение *akt:works-for* между экземпляром класса *akt:Employee* и экземпляром класса *akt:Organization* , отношение *akt:has-affiliation* между экземпляром класса *akt:Person* и экземпляром класса *akt: Organization* , а также отношения *akt:has-main-agent, akt:has-other-agents-involved* между экземплярами классов *akt:Event* и *akt:Generic-Agent*. Из-за наличия в онтологии ОНС таких классов как *онс:participation*, при установлении соответствия между онтологиями возникает систематическая потребность в генерации экземпляров классов, которых до этого не было ни в одной из онтологий.

2 Эксперименты по выравниванию онтологий

Рассмотрим для определенности случай генерации экземпляра класса *онс:participation* по отношению *akt:has-affiliation* между экземпляром класса *akt:Employee* и экземпляром класса *akt:Organization*. Для пополнения открытого архива информацией о местах работы из одного библиографических порталов нам потребуется сначала установить соответствие между экземплярами классов *akt:Person* и *онс:person*, *akt-Organization* и *онс:org-sys*, а затем для каждого факта наличия отношения *akt:has-affiliation* между экземплярами классов *akt:Person* и *akt-Organization* потребуется сгенерировать новый экземпляр класса *онс:participation*, а также связать его отношением *онс:in-org* с соответствующим экземпляром класса *онс:org-sys*, и отношением *онс:participant* с соответствующим экземпляром класса *онс:person*. При обратной трансляции нам потребуется генерировать отношения akt:works-for соответствующие экземплярам класса *онс:participation.*

Поскольку в онтологии ОНС имеется достаточно много классов, аналогичных классу *онс:participation*, систематически возникает необходимость устанавливать соответствие между различными группами классов и отношений этих двух онтологий. А именно, необходимо установить соответствие между группой вида "Class 1-relation1-Class2" онтологии AKT Reference ontology и одной или несколькими группами вида "Class3- relation2-Class4-relation3-Class5" онтологии ОНС. При этом между объектами классов Class1 и Class3 следует установить связи типа *owl:sameAs* также как и для классов Class 2 и Class5. Помимо этого, необходимо сгенерировать экземпляр класса Class4 для каждой тройки <Class1:instance1, relation1, Class2:instance2>. Такая трансляция может быть осуществлена при помощи запроса SPARQL 1.1. Упрощенная версия этого запроса имеет следующий вид:

```
PREFIX iis:<http://iis.nsk.su#>
PREFIX akt:<http://www.aktors.org/ontology/portal#>
PREFIX
akts:<http://www.aktors.org/ontology/support#>
CONSTRUCT {
_:p a iis:Class4.
_:p iis:relation2 ?instance1.
_:p iis:relation3 ?instance2.
}
WHERE {
        ?instance1 akt:relation1  ?instance2.
        ?instance1 a akt:Class1.
        ?instance2 a akt:Class2.
         }
```

Для упрощения задачи нами разработана программа, которая позволяет генерировать SPARQL-запросы на основе визуализации онтологии. Пример установления такого соответствия показан на Рис. 2. Сначала в интерактивном режиме устанавливается соответствие между двумя наборами классов и отношений, а затем автоматически генерируется шаблон SPARQL-запроса, осуществляющий трансляцию данных.

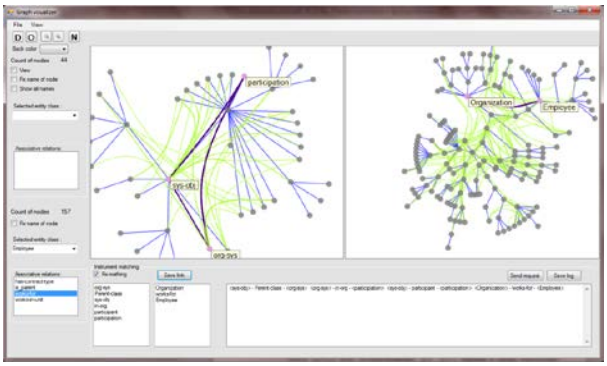

Рис. 2 Интерактивное установление соответствия между классами и отношениями двух онтологий.

3 Проблема установления идентичности сущностей

Как уже было сказано выше, существенным моментом обогащения одной базы знаний при помощи другой является этап установления идентичности сущностей в наборах данных LOD и данных открытого архива, то есть, генерация отношений вида *owl:sameAs.* Рассмотрим следующий пример. В Открытом архиве имеется экземпляр класса *онс:person*, описывающий бывшего директора ИСИ СО РАН В.Е Котова:

```
<person rdf:about="piu_200809052136">
    <name xml:lang="ru">Котов Вадим
Евгеньевич</name>
    <name xml:lang="en">Kotov, Vadim
Yevgenievich</name>
    <from-date>1938-07-23</from-date>
    <sex>m</sex>
  </person>
```

Также, в Открытом архиве СО РАН имеется достаточно подробная информация о его местах работы как в различных организациях СО РАН, так и в США. При этом отсутствует информация о его публикациях. С другой стороны, достаточно много информации о публикациях В.Е. Котова содержится в различных наборах данных облака LOD таких как: acm.rkbexplorer.com, dblp.rkbexplorer.com, citeseer.rkbexplorer.com. Но в этих наборах данных нет информации о местах работы В.Е. Котова, присутствующей в Открытом архиве. Для взаимовыгодного обмена данными надо, прежде

всего, связать отношением *owl:sameAs* экземпляры наборов данных из Открытого архива и LOD. Первая проблема связана с тем, что хоть имена персон и описаны при помощи одного и того же атрибута *akt:full-name* , этот атрибут может иметь разные значения не только в разных наборах облака LOD, но и в одном и том же наборе. Например, в наборе данных http://acm.rkbexplorer.com , в качестве свойства *akt:full-name* используются следующие идентификаторы: Vadim E. Kotov, V. Kotov, Vadim Kotov, V.E. Kotov. При этом каждому из этих имен соответствует отдельный идентификатор персоны, поэтому если мы строим запрос о публикациях, выдается по одной-две публикации соответствующей каждой из этих (РАЗНЫХ!) персон.

В настоящий момент все эти данные собираются в полу-автоматическом режиме при помощи программы SILK[10], на основе регулярных выражений и сравнения лексической близости соответствующих идентификаторов. Понятно, что эта процедура не гарантирует нам того, что мы не объединили вместе информацию об однофамильцах.

Наши эксперименты с полнотекстовыми версиями документов показали, что, во-первых, в них часто указываются места работы авторов, которые можно было бы сравнить с имеющимися в Открытом архиве списком мест и дат работы для каждой персоны. Во-вторых, авторы часто ссылаются на свои прежние публикации, что позволяет связывать в одну цепочку работы одного и того же автора. К сожалению, на сайтах указанного набора эта информация представлена неполно. Редко указаны места работы персон, а их временные границы не указаны совсем. Что же касается списков цитирования, то эта информация на данный момент тоже отражена неполно. Для многих персон из Открытого Архива, редко имеется информация более чем о двух ссылках из списка публикаций каждой из статей. Виду неполноты имеющейся информации планируется в дальнейшем извлекать информацию из полнотекстовых версий публикаций.

Для включения данных о публикациях Котова В.Е. в контент открытого архива, необходимо выполнить следующие трансформации (что опять же связано с различиями в онтологическом строении этих наборов данных). Во-первых, для каждого экземпляра класса *akt: publication-reference* следует создать экземпляр класса *онс:document,* а затем для каждого отношения *akt:has-author* AKT Reference ontology надо сгенерировать объект класса *онс:authorship* онтологии ОНС, после чего сгенерировать отношения *онс:adoc* и *онс:author,* связывающие индивид класса *онс:authorship* с соответствующими индивидами классов *онс:person* и *онс:document*. Эти трансформации выполняются при помощи SPARQL-запроса, аналогичного описанному выше.

4 Визуализация результатов Sparql-запросов для трансформации и анализа наборов данных

Основным инструментом исследования наполнения семантических систем в нашей системе является построение SPARQL-запросов и визуализация их результатов при помощи либо стандартного, либо специализированного алгоритма визуализации. Для этого нами реализована программа, позволяющая генерировать SPARQL-запросы к любой исследуемой семантической системе и получать результаты запроса, как текстовом виде, так и в виде графа. На Рис. 3 показано окно для ввода SPARQL-запросов и вывода результатов запроса в текстовом виде. Окно состоит из трех панелей. Панель справа показывает список основных классов и отношений исследуемой системы, верхняя панель предназначена для ввода SPARQL-запроса. В данный момент там имеется sparql-запрос на генерацию графа, ребрами которого являются отношения «коллега», соответствующие тому, что люди работают в одной организации. Для упрощения понимания запрос генерирует также ребро к вершине, соответствующей организации, в которой работают коллеги. Нижняя панель выдает результаты запроса в текстовом виде. Помимо этого, в верхней правом углу есть две кнопки, позволяющие либо сгенерировать результат запроса в виде графа, либо дополнительно осуществить кластеризацию одной из связных компонент полученного результата. Поскольку данная возможность визуализации предусмотрена для графов произвольной структуры, используется силовой алгоритм[8].

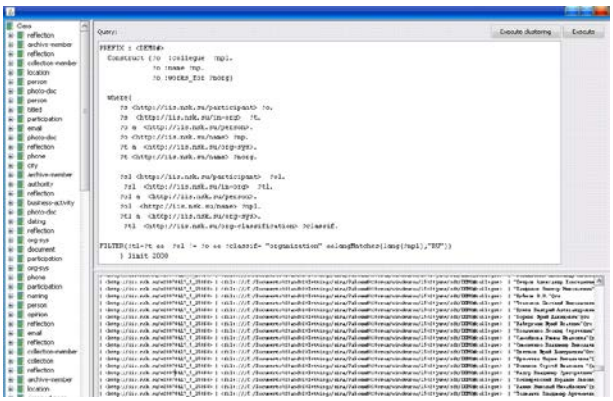

Рис. 3. Окно ввода SPARQL-запросов к исследуемой системе.

На Рис. 4(а) показан результат данного запроса в виде графа.

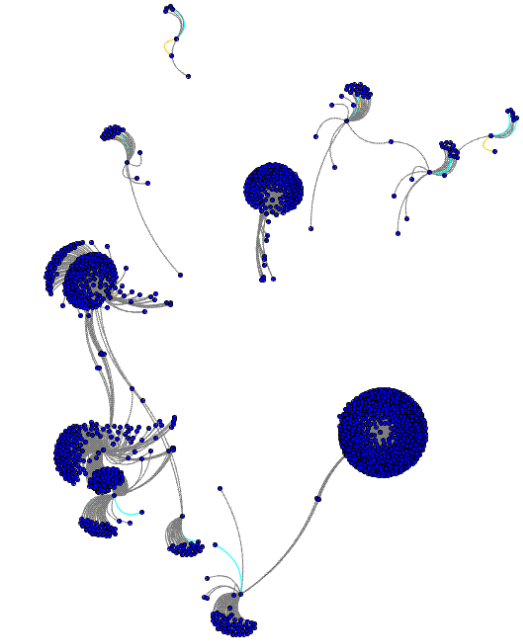

(а)

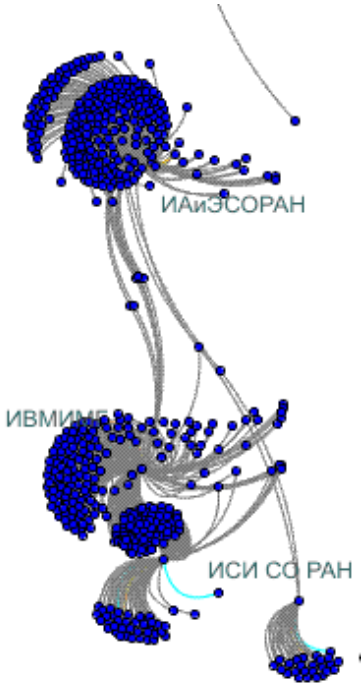

(б)

Рис. 4. Сети, выдаваемые в результате запросов к семантической системе открытого архива СО РАН.

Граф состоит из нескольких компонент связности. Люди сгруппированы вокруг организаций, в которых они работают или работали. Следует отметить, что поскольку указанный запрос не использовал фильтрацию по дате работы, некоторых людей ребра связывают с несколькими организациями. Так на Рис. 4(б) показан фрагмент изображения с Рис. 4(а), на котором видно, что часть коллег связано с ИСИ СО РАН, часть - с ИВМ и МГ, а часть – с обеими организациями. Эта промежуточная часть достаточно велика, поскольку ИСИ СО РАН был создан на базе одного из отделов ИВМ и МГ. Помимо просмотра данных из исследуемых баз данных эта компонента дает нам возможность визуализации и исследования сетей цитирования и соавторства и их кластеризацию, что важно для данного приложения.

Заключение

В данной работе рассмотрены проблемы обогащения научных баз знаний при помощи контента библиографических порталов из облака LOD и подходы к их решению. Сравниваются онтология ОНС и AKT Reference ontology и соответствие между наборами данных, основанных на этих онтологиях, устанавливается при помощи SPARQL-запросов, которые могут быть сгенерированы на основе визуализации онтологий.

Эксперименты показали, что для выравнивания онтологий недостаточно установления простых соответствий и могут потребоваться более сложные шаблоны. Также продемонстрировано, что обычные инструменты, применяемые для установления идентичности сущностей на основе метрик сходства, не позволяют различать авторов публикаций, являющихся тезками или даже однофамильцами. Для решения этой проблемы планируется использовать информацию о временных границах мест работы персон, описанных в Открытом Архиве СО РАН, а также методы изучения сетей самоцитирования.

Благодарности

Работа выполнена при финансовой поддержке РФФИ (проект № 11-07-00388).

Литература

[1] AKT ontology description: http://www.aktors.org/ontology.

[2] Alani, H. TGVizTab: An Ontology Visualization Extension for Protege. // Proceedings of Knowledge Capture (K-Cap'03),Workshop on Visualization Information in Knowledge Engineering, Sanibel Island, Florida, USA. 2003.

[3] Apanovich Z. V., Vinokurov P. S. An extension of a visualization component of ontology based portals with visual analytics facilities. // Bulletin of NCC .— Issue 31.— 2010.— pp. 17-28.

[4] Bizer, C., Heath, T. , Berners-Lee, T. Linked Data - The Story So Far. //Int. J. Semantic Web Inf. Syst., 5 (3). 2009. P. 1-22

[5] CiteSeer dataset : http://citeseer.rkbexplorer.com/.

[6] Cruz I. F., Stroe C., Caimi F., Fabiani A., Pesquita C., Couto F. M., Palmonari M. Using AgreementMaker to Align Ontologies for OAEI

2011. http://ceur-ws.org/Vol-814/oaei11_paper1.pdf

[7] DBLP dataset: http://dblp.rkbexplorer.com/.

[8] Erling O. How Virtuoso uses Relational Technology in its RDF Triple Store and SPARQL implementation. http://virtuoso.openlinksw.com/whitepapers/SPARQL%20RDF%20Store%20using%20SQL-ORDBMS.html

[9] Fruchterman T. M. J., Reingold E. M. Graph Drawing by Force-Directed Placement//Software - Practice and Experience, 1991, Vol. 21, N11, P. 1129-1164.

[10] Isele R., Jentzsch A., Bizer Ch. Silk Server - Adding missing Links while consuming Linked Data// 1st International Workshop on Consuming Linked Data (COLD 2010), Shanghai, November 2010.

[11] Katifori, A., Halatsis, C., Lepouras, G., Vassilakis, C., and Giannopoulou, E. (2007). Ontology Visualization Methods - a Survey. ACM Computing Surveys, 39(4).

[12] B. Kernighan and S. Lin, An efficient heuristic procedure for partitioning graphs, Bell System Technical Journal, 49 (1970), pp. 291- 307.

[13] Ngomo A.-C. N., Auer S.: LIMES - A Time-Efficient Approach for Large-Scale Link Discovery on the Web of Data. //IJCAI 2011: Proceedings of the 22nd International Joint Conference on Artificial Intelligence, Barcelona, Catalonia, Spain, July 16-22, 2011 pp. 2312-2317 .

[14] Oren, E., Delbru, R., Catasta, M., Cyganiak, R., Stenzhorn, H. and Tummarello, G.(2008). Sindice.com: a document-oriented lookup index for open linked data.// Int. J. Metadata, Semantics and Ontologies, Vol. 3, No. 1, pp. 37–52 (2008

[15] Pietriga, E. IsaViz. http://www.w3.org/2001/11/IsaViz .

[16] Sintek, M. Ontoviz tab: Visualizing Protégé ontologies. 2003 http://protegewiki.stanford.edu/wiki/OntoViz.

[17] Storey, M.-A. D. , Muller, H. A. Manipulating and documenting software structures using shrimp views. // Proc. of the Intl. Conf. on Software Mainten. — 1995.

[18] Schultz A. et al. How to integrate LINKED DATA into your application //Semantic technology & Business Conference, San Francisco, June 5, 2012. http://mes-semantics.com/wp-content/uploads/2012/09/Becker-etal-LDIF SemTechSanFrancisco.pdf.

[19] Tramp S., Williams H., Eck K., Creating Knowledge out of Interlinked Data: The LOD2 Tool Stack http://lod2.eu/Event/ESWC2012-Tutorial.html.

[20] Марчук А.Г., Марчук П.А. Особенности построения цифровых библиотек со связанным контекстом //Труды RCDL'2010- Двенадцатая Всероссийская научная конференция «Электронные библиотеки: перспективные методы и технологии, электронные коллекции» Казань, Казанский университет , 2010. — С. 19-23.

[21] Апанович З.В., Винокуров П.С., Кислицина Т.А. Гибкая подсистема визуализации онтологии и информационного наполнения порталов знаний на протяжении их жизненного цикла // Труды RCDL'2010 - Двенадцатая Всероссийская научная конференция "Электронные библиотеки: перспективные методы и технологии, электронные коллекции" Казань, Казанский университет, 2010.— С. 265-272.

Problems of using the LOD cloud datasets to enrich the content of scientific data and knowledge bases

Zinaida V. Apanovich, Alexander. G. Marchuk

This paper describes some problems arising during the use of the LOD cloud datasets to enrich the content of scientific knowledge bases and approaches to their solution. The experiments are carried out with the help of a toolkit intended to simplify analysis and integration of data from different datasets. The dataset of the Open Archive of the Russian Academy of Sciences, based on the ONS ontology, as well as various bibliographic datasets , structured by AKT Reference ontology, are used as test examples.