

ДОКУМЕНТАЛЬНЫЕ ИСТОЧНИКИ ИНФОРМАЦИИ

УДК 7/9:004.774.25

А.Б. Антопольский

Связанные открытые данные в цифровой гуманитаристике (обзор публикаций)

Предлагается обзор применения технологий связанных открытых данных в зарубежных проектах в сфере цифровой гуманитаристики. Выделяется несколько направлений: преобразование в LOD цифровых коллекций по культуре и искусству; интеграция разнородных данных, связанных с событием; библиографические ресурсы; языковые информационные ресурсы; музыкальные и музыковедческие данные. Особый, наиболее ценный вариант проектов по связанным данным – это технологические разработки и инфраструктурные проекты, создающие основу для национальных систем цифровой гуманитаристики. Подчеркивается роль онтологий в реализации проектов связанных данных.

Ключевые слова: связанные открытые данные, цифровая гуманитаристика, цифровые коллекции, интеграция данных, библиографические ресурсы, языковые ресурсы, музыкальные данные

DOI: 10.36535/0548-0019-2022-05-4

ВВЕДЕНИЕ

Технология связанных открытых данных (Linked Open Data – LOD) на платформе Семантической сети, с начала XXI в. стала ведущим направлением для представления научных данных, их интеграции и совместности, а также коллабораций в этой области.

В области общественных (социальных и гуманитарных) наук технология связанных открытых данных также является наиболее перспективным направлением для интеграции информационных ресурсов. Она рассмотрена автором настоящей статьи в монографии [1].

В настоящей статье содержится обзор и анализ применения этой технологии в зарубежных проектах в сфере цифровой гуманитаристики (DH), подготовленный на основе исследования инфосферы DH, результаты которого опубликованы в работе [2].

Среди проектов в области DH, использующих технологию LOD, можно выделить следующие:

- инфраструктурные и технологические проекты на основе LOD;
- преобразование в LOD цифровых коллекций по культуре и искусству;
- интеграция разнородных данных, связанных с событием;
- библиотечно-библиографические ресурсы в LOD;

- языковые информационные ресурсы в LOD;
- представление в LOD музыкальных и музыковедческих данных.

ИНФРАСТРУКТУРНЫЕ И ТЕХНОЛОГИЧЕСКИЕ ПРОЕКТЫ

В настоящей статье не предполагается дать исчерпывающий анализ инфраструктурных и технологических решений, основанных на связанных открытых данных. Мы приведем лишь некоторые примеры, которые были реально использованы в нескольких проектах DH.

Примером инфраструктурного национального проекта связанных открытых данных для цифровых гуманитарных наук является проект LODI4DH [3], реализуемый в Финляндии.

LODI4DH – это совместная инициатива факультета компьютерных наук Университета Аалто и Центра цифровых гуманитарных наук Хельсинкского университета по созданию централизованных национальных сервисов связанных данных для открытой науки.

LODI4DH основан на большой сети для совместной работы и программном обеспечении, созданном в ходе выполнения длинной череды проектов с 2002 г., в результате которых было создано несколько используемых прототипов инфраструктуры, таких как онтология ONKI служба онтологии Finto в Нацио-

нальной библиотеке Финляндии. Эта служба развернула ONKI и занималась ее дальнейшим развитием на основе SKOS и на платформе Linked Data Finland LDF.fi.

ONKI/Finto и LDF.fi уже имеют широкую пользовательскую базу, что свидетельствует о востребованности инфраструктуры LODI4DH. Приложения на их основе также прошли путь от академических исследований до реального использования. Так, серия смысловых порталов Sampo имеет миллионы пользователей в Интернете. Многие музеи Финляндии, например, Городской музей Эспоо, Консорциум 8 музеев AKSELI и новая национальная система каталогизации KOOKOS, используют онтологии ONKI/Finto. В дополнение к финским проектам существует несколько совместных исследовательских проектов с международными университетами, такими как Оксфорд, Стэнфорд, Колорадо и Пенсильвания, в которых использовались финские службы связанных данных для DH. LODI4DH направлена прежде всего на исследовательскую инфраструктуру DH, но лежащие в ее основе технологии связанных данных и Семантической сети могут использоваться и в других областях исследований, что существенно расширяет потенциал этой инфраструктуры.

Так, данные от сотрудничающих организаций объединяются в общие открытые общедоступные онтологии для: 1) исторических мест и карт, 2) исторических лиц, 3) событий, 4) ключевых понятий и 5) времени. Эти основные онтологии, предоставляемые в виде веб-сервисов, применяются в качестве «семантического клея» при связывании и слиянии данных.

Еще один инфраструктурный проект связанных открытых данных LINCS [4] предназначен для канадских культурных исследований. Этот проект обеспечивает преобразование больших наборов данных во взаимосвязанную машинно-обрабатываемую сеть ресурсов. Исследователям нужна более умная семантическая сеть, которая встраивает смысл в машиночитаемые ссылки, чтобы прояснить различные взаимосвязи понятий и объектов. Технологии связанных открытых данных делают сеть умнее, структурируя и интегрируя данные. LINCS использует эти технологии для увязки канадских исследований и данных о наследии из всего Интернета, преобразуя, соединяя, улучшая и делая доступными ранее гетерогенные и разрозненные наборы данных. Такая увязка обеспечивает пути к новым идеям через сетевое производство знаний как внутри Канады, так и за ее пределами.

Как часть этого проекта осуществляется преобразование метаданных в открытые связанные данные о проектах в сфере культуры [5].

Среди технологических проектов, направленных на развитие LOD, можно указать на метод кодирования связанных данных с помощью JSON (JSON-LD). Соответствующая рекомендация разработана рабочей группой консорциума World Wide Web [6]. Одна из целей JSON-LD заключалась в том, чтобы потребовать от разработчиков как можно меньше усилий для преобразования существующего JSON в JSON-LD. В настоящее время этот стандарт поддерживается Рабочей группой JSON-LD [7].

Проект LodLive [8], разработанный группой итальянских специалистов, демонстрирует использование стандартов связанных данных (RDF, SPARQL) для просмотра ресурсов RDF. Приложение направлено на распространение принципов связанных данных с использованием простого и дружественного интерфейса с многообразными методами. Основной принцип, лежащий в основе LodLive, заключается в том, чтобы доказать, что ресурсы, публикуемые в соответствии со стандартом W3C SPARQL, могут быть легко доступны и понятны. Проект предполагает, что подход LodLive может стимулировать государственные администрации и крупных владельцев данных добавлять свои ресурсы в LOD и делиться ими. Можно начинать просмотр, запросив конечную точку для определенного ресурса, или начать с одного из приведенных примеров URI.

Веб-инструмент LodLive разработан для демонстрации стандартов связанных данных, применяемых к просмотру ресурсов RDF с помощью простого интерфейса. LodLive состоит из подключаемого модуля jQuery (lodlive-core.js), карты конфигурации JSON (lodlive-profile.js), HTML-страницы, нескольких изображений (спрайтов) и некоторых других общедоступных плагинов jQuery.

Интересный проект разработан кафедрой цифровых гуманитарных наук Университета Этвёша Лоранда (Венгрия) [9]. Он называется ELTEdata и направлен на организацию просопографических, библиографических и других данных в семантическую сеть и их публикацию. ELTEdata следует структуре Викиданных, связанной с Викиданными семантическими утверждениями и сущностями. Таким образом, ELTEdata может быть интерпретирована как часть Викиданных, хотя и полностью независима от этого ресурса.

Элементы ELTEdata имеют уникальный идентификатор, и каждый семантический оператор может быть описан как пара *свойство–значение*. Язык семантических запросов SPARQL обеспечивает сложный поиск и визуализацию на карте или временной шкале. Эта функция позволяет структурировать большой набор данных и кажется полезной при описании сетей. Слияние с внешними базами данных играет важную роль в формировании семантической библиографии, поэтому актуально сопоставлять некоторые свойства семантических операторов с их вариантами, содержащимися в интерфейсах структурированных метаданных.

К технологическим проектам в области DH можно отнести и проект LIDER *Связанные данные как средство кросс-медиа и многоязычной аналитики контента* [10], определяющий архитектуру, которая создается для анализа многоязычного и мультимедийного контента. Эталонная архитектура LIDER основана на открытых стандартах, существующих и будущих платформах и обеспечивает:

- эталонную модель, определяющую задачи, в которых лингвистические связанные данные могут поддерживать контент-аналитику, и обеспечивающую стандартную декомпозицию этих задач на элементы, которые совместно могли бы решать эти задачи вместе с потоками данных между элементами;

- каталог архитектурных шаблонов, описывающий типы элементов, которые могут быть использованы в вышеупомянутых задачах, типы взаимосвязей между этими элементами, и ограничения на то, как они могут быть использованы.

В проекте описываются различные источники информации для этой эталонной архитектуры, проблемы и препятствия, которые решены лишь частично. Собрана и упорядочена обширная коллекция задач и архитектурных шаблонов NLP в качестве основы для разработки согласованной справочной архитектуры, которая ориентирует первых пользователей данных на основе ссылок из целевых групп лидеров промышленных заинтересованных сторон. Кроме того, эталонная архитектура LIDER включена в контекст деятельности в области связанных данных.

КОЛЛЕКЦИИ КУЛЬТУРНОГО НАСЛЕДИЯ

Центральным направлением цифровой гуманитаристики, вероятно, следует признать создание и обработку разнообразных цифровых коллекций артефактов, относящихся к культурному наследию. Таких проектов в ходе проведенного обследования было выявлено достаточно много. Среди них было несколько, использующих технологии семантической сети и LOD.

Один из наиболее крупных проектов такого рода – это проект ModRef [11] (моделирование, репозиторий, цифровая культура), который объединяет проекты лаборатории Labex PasP [12] из Университета Парижа в Нантере и обеспечивает взаимодействие нескольких организаций таких, как:

- MoDyCo (моделирование, динамика, корпус) [13],
- BDIC (Международная библиотека современной документации) [14],
- MAE (Дом археологии и этнологии) [15],
- ArScAn (Археология и античная наука) [16].

Цель ModRef состоит в том, чтобы провести цифровую экспертизу проектов Labex, а также доказать справедливость концепции LOD. В задачу проекта входит разработка моделирования с использованием ссылок.

Проект ModRef должен стимулировать обсуждение вопросов, связанных с миграцией данных в веб-семантику путем создания и использования «хранилищ троек» (коллекций или хранилищ данных RDF-файлов).

Перемещение данных в хранилища троек включает в себя различные этапы:

- подготовка данных (исследование и структурное описание данных),
- семантическое моделирование и сопоставление данных (или сопоставление и выравнивание),
- создание хранилищ троек – перенос данных в хранилища троек,
- публикация и визуализация хранилища троек,
- интерфейс для выполнения sparql-запросов в хранилища троек.

Основные проблемы – это (1) переход от неструктурированных или полуструктурированных данных (блокнот, тексты, html) к структурированным данным (электронные таблицы, реляционные базы данных, XML-файлы), а затем (2) перемещение этих структурированных данных в семантические данные (RDF-файлы) с целью улучшения обмена и открытия новых знаний.

В качестве нормированной онтологии была выбрана CIDOC-CRM [17], поскольку в настоящее время она является справочной для семантического описания данных в музеографическом или культурном наследии.

CIDOC-CRM доступна в формате OWL, который предоставил Университет Эрлангена-Нюрнберга [18].

Следует отметить, что на сайте ModRef приводится перечень организаций, которые работают над преобразованием метаданных каталогов своих коллекций культурного наследия в связанные открытые данные, часть из них использует в качестве онтологии CIDOC-CRM:

- Британский музей [19],
- Йельский центр британского искусства [20],
- Arches [21] – результат сотрудничества между Институтом сохранения Гетти (GCI) и Всемирным фондом памятников (WMF) по недвижимому культурному наследию,

- Портал Biblissima [22] предоставляет унифицированный доступ к набору цифровых данных о средневековых рукописях, инкунабулах и раннепечатных книгах, выпущенных партнерами консорциума Biblissima. На сайте указано, что предполагается представление всех данных проекта в формате LOD. В настоящее время в этом формате доступны авторитетные файлы системы.

Упомянутые на сайте ModRef известные проекты ДН вместо онтологии CIDOC-CRM используют другие системы метаданных, в том числе:

- Онлайн-энциклопедию DBpedia [23] – системы метаданных dbpedia, foaf, umbel, schema.org, dublicore, geo,
- Сервис для хранения, документирования и публикации данных Nakala [24] – системы метаданных foaf, skos, dublicore, vcard,
- Платформа исторической информации Symogih [24] – системы метаданных symogih, example.org, geo.

Потребность в создании связанных открытых данных была рассмотрена в проекте PHAROS Международного консорциума фотоархивов [26]. Это первый шаг на пути к разработке реальной цифровой инфраструктуры фотографических архивов произведений искусства в Европе и Соединенных Штатах Америки. Консорциум организовал сотрудничество между учреждениями, ответственными за четырнадцать фотоархивов с тем, чтобы создать общую платформу для исследований изображений и метаданных.

В качестве примера работы с фотоархивами опишем проект преобразования метаданных фотоархива Зери в LOD [27], который включает 290 тыс. фотографий памятников и произведений искусства. Каталогизация хранилища Зери была проведена на основе двух итальянских стандартов метаданных: Scheda F для фотографий и Scheda OA для произведений искусства.

Первый выпуск набора данных Zeri Photo Archive RDF представляет собой значительное подмножество данных, уже доступных на веб-сайте каталога Zeri и для поиска через портал Europeana – это в основном произведения искусства Нового времени (XV–XVI вв.): около 19.000 – сами произведения и более 30 тыс. фотографий, описанных с помощью примерно 11 млн троек RDF.

ИНТЕГРАЦИЯ ДАННЫХ, СВЯЗАННЫХ С СОБЫТИЕМ

Наиболее интересное с точки зрения цифровой гуманитаристики применение технологии LOD заключается в методике интеграции данных и метаданных, посвященных историческим или культурным событиям и объектам культурного наследия, в разных системах хранения, прежде всего в библиотеках, архивах, музеях. Нам уже приходилось делать обзор методов интеграции таких данных [28]. Однако в последние годы в мире было реализовано много новых проектов, интегрирующих разнородные данные на основе технологии LOD. Здесь мы опишем более подробно два таких проекта из различных сфер цифровой гуманитаристики, и кратко – еще несколько.

Первый пример из области социальной психологии. Проект направлен на представление информации по *Стэнфордскому тюремному эксперименту (SPE)* в виде LOD [29] и начинается с отбора по критериям релевантности и неоднородности исходных пунктов (документов), отражающих содержание события (SPE) с различных точек зрения. Для каждого пункта предоставляются основные метаданные, краткое описание и справочная ссылка.

На основе этих пунктов были идентифицированы сущности SPE и отношения между ними. Полученная сложная сеть сущностей затем была очерчена с помощью концептуальной карты (хотя карта является лишь предварительным эскизом, она дает четкий обзор и общее понимание сценария проекта), на основе которой строится модель E/R (сущность/отношение) для SPE. Далее выполняется анализ метаданных и их выравнивание, т.е. приведение к фиксированному списку используемых систем метаданных. Инструментом выравнивания послужил стандарт Dublin Core.

Для каждого объекта разработчики этой модели попытались ответить на вопросы WHO?, WHERE?, WHEN? и WHAT?, определив свойства этих объектов и оформив их в виде стандартных терминов (дескрипторов).

Теоретическая модель подробно предоставляет список свойств, установленных для каждого элемента, и связи между всеми сущностями, включенными в проект, определяя свойства на некоторых авторитетных онлайн-ресурсах таких как, Wikidata, DBpedia, TMDb, Last.FM, Getty Vocabularies, WorldCat и т. д. Эта модель позволила уточнить и расширить модель E/R.

Переходя от теоретической модели к концептуальной модели, разработчики определили наиболее подходящие онтологии, чтобы детально представить элементы проекта. Для подбора онтологий были использованы некоторые инструменты, в частности схема классификации Seeing Standards [30] и портал Linked Open Vocabularies (LOV) [31]. Были выбраны такие наиболее распространенные онтологии:

- *FOAF* (Friend Of A Friend) – онтология, описывающая людей, их деятельность и их отношения с другими людьми и объектами;
- *Schema.org* – стандарт семантической разметки данных в сети, объявленный летом 2011 г. поисковыми системами Google, Bing и Yahoo!;
- *Дублинское ядро*. Термины перечисляют текущий набор словаря Dublin Core, т. е. 15 основных

элементов плюс все квалифицированные термины. Он может использоваться для нескольких целей – от простого описания ресурсов до объединения словарей метаданных различных стандартов метаданных и до обеспечения совместимости словарей метаданных в связанном облаке данных и реализациях семантической паутины;

- *CIDOC-CRM*, в настоящее время ISO/CD21 127, является основной онтологией, цель которой – обеспечение обмена и интеграции между разнородными источниками информации о культурном наследии, архивами и библиотеками;

- *VIVO* – библиографическая онтология предоставляет основные понятия и правила для описания цитат и библиографических ссылок (т.е. цитат, книг, статей и т.д.);

- *Онтология соглашений* предназначена для моделирования социальных контрактов, которые включают лицензии, законы, контракты, стандарты и метаданные определений;

- *Музыкальная онтология* предоставляет словарь для публикации и связывания широкого спектра данных, связанных с музыкой, в Интернете.

Для всех сущностей в этой модели были построены пространства имен и определены уникальные идентификаторы. Это позволило сформировать RDF-тройки, которые размещены на сайте. Конечная цель проекта – формирование графа знаний события.

Другой пример – интеграция разнородных объектов и сущностей, связанных со сложным историческим событием – «*Фестивалем музыки и искусств Вудсток*» [32]. Главная цель этого проекта – попытка добиться взаимосвязанной системы информации о событии, отталкиваясь от уже существующих в сети ресурсов. Схема выполнения проекта похожа на уже описанную. Сначала были выбраны 10 объектов из разных библиотек, архивов, музеев, посвященных Вудстоку. Для этих объектов на основе естественного языка с помощью интуитивно понятной модели E/R были выделены основные сущности и отношения. Затем разработчики проекта проанализировали стандарты метаданных, которые использовались при описании объектов. Сущности и отношения сравнивались со стандартами метаданных, чтобы выявить наиболее важные аспекты в описании данных.

Когда получили более четкое представление о предметной области, было проведено моделирование данных на абстрактном уровне: построена теоретическая модель, обеспечивающая общее естественноязычное описание информации о сущностях и отношениях, задействованных в проекте.

Это был промежуточный этап, ведущий к созданию концептуальной модели, способной формализовать описание особенностей данных за счет использования уже существующих онтологических формальных языков. Благодаря различным онтологиям удалось представить и описать данные как формализованные понятия, пригодные для выражения RDF-высказывания в виде триплетов, представленных субъектами, предикатами и объектами. Полученные RDF-высказывания были сериализованы через Turtle, что позволило представить данные в виде триплета URI, выраженного – где это возможно – через онтологические словари.

Были созданы такие взаимосвязи между полученными данными, данными органов власти и других организаций, участвующих в проекте, а также другими ресурсами из онлайн-репозитория или веб-страниц.

Наконец, все результаты проекта были представлены в виде графа знаний, изображающего контекстуализированную информационную сеть данных, связанных с фестивалем Вудстока, что позволило выявить скрытые отношения, составляющие реальную сущность чего-либо.

Кратко опишем еще несколько проектов такого рода.

WarSamp [33] – это первая крупномасштабная система для обслуживания и публикации LOD о Второй мировой войне: 1) инициирует и способствует крупномасштабной публикации этих данных из распределенных разнородных хранилищ и 2) демонстрирует и предлагает их использование в приложениях и исследованиях DH. Граф знаний содержит более 9 млн высказываний (троек) между элементами данных, включая, например, полный набор из более чем 95 тыс. записей о смертях финских солдат во время Второй мировой войны. В виде RDF-высказываний представлены 160 тыс. сделанных во время войны подлинных фотографий, в том числе 32 тыс. фото исторических мест на исторических картах, 23 тыс. военных дневников воинских частей и 3400 мемуарных статей, написанных ветеранами после войны. Информация в *WarSampo* поступает из нескольких финских организаций и источников.

WarSampo состоит из двух отдельных компонентов: 1) служба данных *WarSampo* для машин и 2) семантический портал *WarSampo* с различными приложениями для пользователей.

Цель проекта *Битва при Ватерлоо в формате LOD* [34] – создание абстрактной модели LOD для описания данных, связанных с битвой при Ватерлоо. Модель должна соотнести событие с личностью «Наполеон Бонапарт», местом «Ватерлоо», датой «1815» и концепцией «Поражение». Последовательность действий: выбор 10 предметов, включающих архивные документы, публикации и артефакты, описывающие идею «Битва при Ватерлоо»; согласование между используемыми учреждениями культурного наследия различными стандартами метаданных, относящимися к людям, месту, дате и концепции. Цель – разработка модели, способной описывать выбранные предметы, и отвечать на вопросы:

- Как описать людей?
- Какая информация о местах?
- В каком формате понятие времени?
- Каково основное содержание объектов?

Модель должна применять существующие формальные системы и онтологии такие, как FOAF, RDFS, SKOS, DC, EAC-CPF.

История экспедиции «Кон-Тики» в формате LOD [35]. При реализации этого проекта была сделана подборка из десяти предметов, связанных с историей Кон-Тики. Для каждого предмета указано название, тип, связанный источник и краткое описание. Сценарий был представлен через модель E/R, содержащую выбранные элементы, сущности и наиболее релевантные отношения между ними. Затем были опре-

делены стандарты метаданных, принятые для описания этих предметов.

Чтобы обеспечить функциональную совместимость между стандартами, были определены соответствия между свойствами метаданных. Теоретическая модель – это сценарий, описывающий элементы, связанные метаданные и отношения между ними в абстрактном виде. Модель формально представляет рассматриваемое событие, используя существующие онтологии: графическое изображение было создано, чтобы показать результирующую модель. Выбранные элементы описаны в соответствии с концептуальной моделью с помощью набора таблиц, каждая из которых представляет предметы, предикаты и объекты, подходящие для описания особенностей предметов и основных событий. Сущности и элементы, репрезентативные для данной области, были записаны в виде высказываний RDF, а затем с использованием сериализации Turtle, представлены и объединены. В результате получено графическое изображение знаний о данном событии.

Еще один проект – представление в виде LOD метаданных объектов разных типов (из архивов, музеев, библиотек) по различным аспектам фильма "*Сладкая жизнь*" [36]. По случаю шестидесятилетия выхода этого фильма была реализована модель LOD, ориентированная на интеграцию данных о производстве и распространении этого культового фильма режиссера Федерико Феллини. Данные, когда они изолированы, имеют ограниченный потенциал, их ценность возрастает, когда один или несколько наборов данных, подготовленных и опубликованных независимо и различными субъектами, предлагают возможность интеграции и контакта между ними с целью создания нового общего знания.

Проект История политического диссидента в формате LOD [37] исследует такое событие, как задержание Патрика Заки и его содержание в египетской тюрьме. Цель проекта – моделирование LOD, устанавливающих концепции, предметы, людей, учреждения и места, связанные с задержанием Патрика Заки, чтобы отобразить семантически значимую среду наиболее интегрированным образом.

Было рассмотрено 4 понятийные области:

- эмоции художников, которые создавали визуальные произведения искусства и музыку об этом событии;
- контекстуальная информация об окружающей среде, связанной с Патриком в прошлом и настоящем, об учебном заведении, здании, в котором его задержали;
- условия содержания в тюрьмах Египта на основе докладов Хьюман Райтс Вотч и подкаста итальянского радио RAI;
- юридические аспекты этого события по резолюции, принятой Европейским парламентом, и петиции, подписанной учеными в защиту Заки.

В проекте были изучены возможные технологии, используемые в семантической сети. Упомянем еще два проекта данного класса:

- интеграция ресурсов библиотек, архивов и музеев, связанных с гибелью «Титаника», с использованием LOD [38];

○ исследование гендерной проблематики в искусствоведении на основе ARTchives и Викиданных, с использованием технологии LOD [39].

Приведенные примеры убедительно показывают возможность использования технологии связанных открытых данных – LOD для тематически и функционально различных областей цифровой гуманитаристики – DH, когда ставится задача представить по возможности полную информацию о событии с использованием разнородных источников.

БИБЛИОТЕЧНО-БИБЛИОГРАФИЧЕСКИЕ РЕСУРСЫ В ТЕХНОЛОГИИ СВЯЗАННЫХ ОТКРЫТЫХ ДАННЫХ

Специфическим видом ресурсов, которые также можно отнести к области цифровой гуманитаристики, являются библиотечные данные, в том числе библиотечные каталоги, библиографические БД и авторитетные (нормативные) файлы. Библиотечные данные очень удобно представлять в виде связанных открытых данных, и работы в этом направлении в ведущих библиотеках мира ведутся с начала XXI в.

Специально для представления библиотечных данных в LOD разработаны модель Библиотеки Конгресса BIBFRAME [40] и модель Международной федерации библиотечных ассоциаций [41], которые активно применяются различными библиотеками. Общее состояние внедрения LOD в библиотеки можно оценить по опросу, который проводил OCLC [42]. Цель этого опроса – изучение опыта тех библиотек, где реализованы или реализуются проекты/услуги связанных данных. Результаты этого опроса приводятся на сайте OCLC [43], а также в презентации [44]. OCLC и сам ведет исследования технологии LOD [45]. В рамках этого пилотного проекта OCLC и пять партнерских учреждений изучили методы и целесообразность преобразования метаданных в связанные данные для улучшения возможности обнаружения и управления оцифрованными культурными материалами и их описаниям.

В российской информатике известность получил проект О.Л. Лавреновой и ее коллег по представлению в формате LOD классификации знаний, а именно Библиотечно-библиографической классификации (ББК) [46].

Последовательным пропагандистом применения связанных данных в библиотечном деле является О.Н. Жлобинская. Один из последних принадлежащих ей обзоров зарубежного опыта представлен в презентации [47]. Развернутая модель преобразования в LOD библиографических данных из формата RUSMARC, разработанная этим автором, содержится в работе [48].

ЯЗЫКОВЫЕ ИНФОРМАЦИОННЫЕ РЕСУРСЫ

Наиболее очевидным и адекватным объектом для представления в виде связанных данных являются языковые информационные ресурсы, поскольку аналогичные языковые ресурсы в форме тезаурусов и онтологий активно создавались в течение последних десятилетий, а исследование семантических сетей – это традиционная область лингвистической семантики.

Описание технологии LOD применительно к языковым информационным ресурсам и современное состояние языковых связанных открытых данных (LLOD) содержится в монографии Ф.Джимиано и его соавторов [49]. Некоторые действующие проекты в этой области рассмотрены в нашей работе [50]. Поэтому в настоящей статье мы ограничимся перечислением языковых связанных открытых данных и проектов, вошедших в цитированное выше исследование инфосферы цифровой гуманитаристики:

- лингвистические связанные открытые данные [51];
- формат кросс-лингвистических связанных данных [52];
- преобразование лингвистических данных в связанные открытые данные [53];
- кросс-лингвистические связанные данные [54];
- связанные открытые словари [55];
- связанные данные в лингвистике [56];
- связывание корпусных данных способом удобным для NLP [57];
- информация о языках в формате связанных данных [58];
- словари Getty как связанные открытые данные [59].

Кажется, что единственный российский проект этого направления – это проект Д. Усталова по интеграции тезаурусов русского языка в связанные данные [60].

Предложенный список не является исчерпывающим, но дает достаточно полное представление о масштабах применения технологии LOD к компьютерной лингвистике.

МУЗЫКАЛЬНЫЕ И МУЗЫКОВЕДЧЕСКИЕ СВЯЗАННЫЕ ДАННЫЕ

Разработки в области цифровизации музыкальных данных и тем более представление их в виде связанных данных – это относительно новое направление цифровой гуманитаристики и поэтому не получило такого развития, как перечисленные выше. В нашем исследовании было обнаружено два подобных проекта, краткие сведения о которых мы приводим.

Встраивание графов и преобразование музыкальных данных в связанную форму [61]. Цель настоящего проекта состояла в том, чтобы извлечь необработанные данные о музыкальных записях и преобразовать их в связанную форму, из которой можно извлечь знания.

Авторы проекта указывают, что известные ресурсы DBpedia [62] и Викиданные уже предлагают огромное количество сущностей, связанных с музыкой, но для непопулярных музыкальных записей их свойства часто очень ограничены. Использование гораздо более широкого набора данных, специализированных на музыкальных записях, позволяет делать более интересные и точные прогнозы. В области музыкальных записей это может позволить создать систему, которая не только автоматически предсказывает жанры, характеристики и особенности альбомной записи, но и вероятность ее сходства с учетом средних оценок, выставленных пользователем.

Джазовые коллекции в LOD – ресурс для изучения джазовых исполнителей, выступлений и сетей [63].

Проект использует семантические веб-технологии для соединения данных о джазе, включая дискографии, сольные транскрипции и информацию об исполнителях. Проект предполагает интеграцию с другими наборами данных и разработку интерфейса для семантического поиска и визуализации данных.

ЗАКЛЮЧЕНИЕ

Из приведенного обзора связанных открытых данных в цифровой гуманитаристике с очевидностью следует, что в мире сложилась методика создания информационного ресурса для анализа предметной области на основе технологии связанных данных. Чаще всего эта технология применяется при формировании графа знаний применительно к событию, персоне, или тематической коллекции. Для таких направлений цифровой гуманитаристики как библиотечные и языковые данные разработаны специфические модели преобразования данных в форму связанных открытых данных 8 – LOD.

Особый, наиболее ценный вариант работ по связанным данным – это технологические разработки и инфраструктурные проекты, создающие основу для национальных систем цифровой гуманитаристики, как это сделано в Финляндии и в Канаде.

Важная особенность проектов по связанным данным заключается в том, что они опираются на уже созданные онтологии и системы метаданных, которые фиксируют сложившийся в мировой науке консенсус по представлению знаний в определенных областях. Поэтому необходимо создание русскоязычной онтологии гуманитарного знания на основе как российских, так и международных источников, что могло бы стать важным компонентом инфраструктуры российской цифровой гуманитаристики.

СПИСОК ЛИТЕРАТУРЫ

1. Антопольский А.Б., Ефременко Д.В. Инфосфера общественных наук России: монография / под ред. В.А. Цветковой. – Москва; Берлин : Директ-Медиа, 2017. – 676 с. DOI 10.23681/468227.
2. Антопольский А.Б. Инфосфера цифровой гуманитаристики: опыт анализа // Информационные ресурсы России. – 2022. – № 1. – С. 30-38.
3. Linked Open Data Infrastructure for Digital Humanities in Finland (LODI4DH). – URL: <https://seco.cs.aalto.fi/projects/lodi4dh/>
4. Linked Infrastructure for Networked Cultural Scholarship. – URL: <https://lincsproject.ca/>
5. CoDHR. – URL: <http://codhr.dh.tamu.edu/2018/04/24/linked-infrastructure-for-networked-cultural-scholarship-lincs>
6. JSON-LD 1.1 A JSON-based Serialization for Linked Data. Draft Community Group Report 19 April 2019. – URL: <https://json-ld.org/spec/latest/json-ld/>
7. JSON-LD Working Group. – URL: <https://www.w3.org/2018/json-ld-wg/>
8. Live on LodLive. – URL: <http://en.lodlive.it/>
9. ELTEdata-project. – URL: https://eltedata.elte-dh.hu/wiki/Main_Page
10. LIDER: FP Linked Data as an enabler of cross-media and multilingual content analytics for enterprises across Europe FP7-610782D3. – URL: <https://docplayer.net/139432478-Lider-fp-linked-data-as-an-enabler-of-cross-media-and-multilingual-content-analytics-for-enterprises-across-europe.html>
11. ModRef Project: Modelling, References, Digital Culture. – URL: <http://modref-labexpassespresent.humanum.fr/ModRef/>
12. Labex Past in Present: history, heritage, remembrance – Labex Les Passés dans le Présent: histoire, patrimoine, mémoires. – URL: <http://passes-present.eu/>
13. MoDyCo. – URL: <http://www.modyco.fr/fr/>
14. Bibliothèque de la Documentation Internationale Contemporaine. – URL: <http://www.bdic.fr/>
15. Maison de L'Archéologie et de L'Ethnologie. – URL: <http://www.mae.u-paris10.fr/>
16. Archéologies et Sciences de l'Antiquité (ArScAn). – URL: <http://www.arscan.fr/>
17. CIDOC-CRM. – URL: <http://www.cidoc-crm.org>
18. The Erlangen CRM / OWL. – URL: <http://www.erlangen-crm.org/>
19. The British Museum. Explore the collection. – URL: <https://www.britishmuseum.org/collection>
20. Yale Center for British Art. – URL: <https://britishart.yale.edu/collections/using-collections/technology/linked-open-data>
21. The Getti Conservation Institute Arches Project. – URL: http://www.getty.edu/conservation/our_projects/field_projects/arches
22. Biblissima, the Observatory for Medieval and Renaissance Written Cultural Heritage. – URL: <https://biblissima.fr>
23. DBPedia. – URL: <http://www.dbpedia.org/sparql>
24. NAKALA. – URL: <https://www.nakala.fr/about>
25. SyMoGIH project. – URL: <http://www.symogih.org/>
26. PHAROS. – URL: <http://pharosartresearch.org/>
27. The Zeri & LODE project. – URL: <http://data.fondazionezeri.unibo.it/>
28. Антопольский А.Б. Интеграция библиотечных и архивных информационных систем. – [Б.и.] . – 5 с. – URL: <https://rucont.ru/efd/158>
29. The Stanford Prison Experiment on LOD. – URL: <https://spelod.github.io/#erModel>
30. Seeing Standards: A Visualization of the Metadata Universe. – URL: <http://jennriley.com/metadatamap/>
31. Linked Open Vocabularies (LOV). – URL: <https://lov.linkeddata.es/dataset/lov>
32. Woodstock Music and Art Festival. – URL: <https://woodslo.d.github.io/woodsLOD/>
33. WarSampo Finnish World War II on the Semantic Web. – URL: <https://www.sotasampo.fi/en/>
34. Battle of the WaterLOD. – URL: <https://waterlod.github.io/index.html>
35. The Kon-Tiki Expedition. A Linked Open Data project. – URL: <https://kontikilod.github.io/KonTiki/>
36. La Dolce Vita – Linked Open Data. – URL: <https://fellini-lod.github.io/contenuto.html>
37. Patrick aLOuD. – URL: <https://patrickaloud.github.io/>
38. The INKING of RMS Titanic. – URL: <https://linkingoftitanic.wixsite.com/linkingtitanic>
39. Martrioska. – URL: <https://martrioska.github.io/martrioska.html>

40. Bibliographic Framework Initiative. – URL: <https://www.loc.gov/bibframe/>
41. IFLA Library Reference Model. – URL: <https://www.librarianshipstudies.com/2020/04/ifla-library-reference-model-lrm.html>
42. Online Computer Library Center. – URL: <https://www.oclc.org/en/home.html?Redirect=true>
43. Linked Data Survey results 6 – Advice from the implementers. – URL: <https://hangingtogether.org/linked-data-survey-results-6-advice-from-the-implementers/>
44. Smith-Yoshimura K. Linked data implementations – who, what, why? – URL: <https://www.oclc.org/content/dam/research/events/2018/smith-yoshimura-linked-data-implementations-who-whatwhy-SWIB18.pptx>
45. Bahnemann G., Carroll M., Clough P., Einaudi M., Ewing Ch., Mixter J., Roy J., Tomren H., Washburn B., Williams E. Transforming Metadata into Linked Data to Improve Digital Collection Discoverability: A CONTENTdm Pilot Project. – Dublin, OH: OCLC Research, 2021. – URL: <https://doi.org/10.25333/fzcv-0851>.
46. LINKED OPEN DATA. Классификационная система организации знаний. – URL: <https://lod.rsl.ru/>
47. Жлобинская О.Н. Библиотечные связанные данные: анализ зарубежного опыта. – URL: <http://www.nilc.ru/text/NMLBD/NMLBD4.pdf>
48. Жлобинская О.Н. Представление библиотечных данных в LOD: возможности и перспективы формата RUSMARC. – URL: http://www.rusmarc.ru/publish/%D0%92%D0%BE%D0%B7%D0%BC%D0%BE%D0%B6%D0%BD%D0%BE%D1%81%D1%82%D0%B8%20%D0%B8%20%D0%BF%D0%B5%D1%80%D1%81%D0%BF%D0%B5%D0%BA%D1%82%D0%B8%D0%B2%D1%8B%20RUSMARC_%D0%A0%D0%BE%D1%81%D1%82%D0%BE%D0%B2.pdf
49. Cimiano Ph., Chiarcos Ch.; McCrae J. P.; Gracia J. Linguistic Linked Data: Representation, Generation and Applications. – Springer International Publishing, 2020.
50. Антопольский А.Б. Лингвистические связанные открытые данные: состояние и перспективы // Научно-техническая информация. Сер. 2. – 2021. – № 8. – С. 28-36. DOI: 10.36535/0548-0027-2021-08-4
51. Linguistic Linked Open Data. – URL: <http://linguistic-lod.org/>
52. Cross-Linguistic Data Formats. – URL: <https://clldf.clld.org/>
53. The Prêt-à-LLOD Project. – URL: <https://pret-a-lod.github.io/>
54. CLLD – Cross-Linguistic Linked Data. – URL: <https://clld.org/>
55. Linked Open Dictionaries. – URL: <http://ionov.me/liodi/>
56. Workshop on Linked Data in Linguistics (LDL). – URL: <https://www.aclweb.org/anthology/venues/ldl/>
57. CoNLL-RDF: Linked Corpora Done in an NLP-Friendly Way. – URL: https://www.researchgate.net/publication/318134320_CoNLL-RDF_Linked_Corpora_Done_in_an_NLP-Friendly_Way
58. Lexvo.org. – URL: <http://www.lexvo.org>
59. Getty Vocabularies as Linked Open Data. – URL: <http://www.getty.edu/research/tools/vocabularies/lod/index.html#definition>
60. Усталов Д.А. Тезаурусы русского языка в виде открытых связанных данных. – URL: <https://www.dialog-21.ru/media/1103/ustalovda.pdf>
61. Graph embedding and link prediction starting from a non-linked musical dataset. – URL: <https://alerosae.github.io/FromRaw2Linked/>
62. DBpedia. Global and Unified Access to Knowledge Graphs. – URL: <https://www.dbpedia.org/>
63. JazzCats (Jazz Collection of Aggregated Triples). – URL: <https://jazzcats.cdhr.anu.edu.au/>

Материал поступил в редакцию 17.02.22.

Сведения об авторе

АНТОПОЛЬСКИЙ Александр Борисович – доктор технических наук, профессор, главный научный сотрудник ИНИОН РАН, Москва
e-mail: ale5695@yandex.ru