

**Технологии XML – как основа интеграции данных
в информационно-библиотечных системах**

**XML-technologies – a Basis for Data Integration
within Library Information Systems**

**Технології XML – як основа інтеграції даних
в інформаційно-бібліотечних системах**

Н. А. Мазов

*Институт нефтегазовой геологии и геофизики им. Академика А. А. Трофимука
Сибирского Отделения РАН, Новосибирск, Россия*

О. Л. Жижимов

*Институт вычислительных технологий Сибирского Отделения РАН,
Новосибирск, Россия*

Nikolay Mazov

*Ac. A. A. Trofimuk Institute of Oil and Gas Geology and Geophysics
of the Siberian Branch of the Russian Academy of Sciences, Novosibirsk, Russia*

Oleg Zhizhimov

*Institute of Computational Technologies of the Siberian Branch
of the Russian Academy of Sciences, Novosibirsk, Russia*

М. О. Мазов

*Институт нефтегазовой геологии та геофизики ім. Академіка А. А. Трофимука
Сибірського відділення РАН, Новосибірськ, Росія*

О. Л. Жижимов

*Институт обчислювальних технологій Сибірського відділення РАН,
Новосибірськ, Росія*

Бурное развитие в последнее время XML-технологий, а также рост программных продуктов, оперирующих с данными в формате XML, предоставляет стандартную возможность кодирования содержания информационных документов, обеспечивая при этом гибкость в создании структур данных, переносимость на различные аппаратно-программные платформы. Иерархическая структура библиографической записи хорошо согласуется с моделью XML-документа. Использование XML в качестве формата обмена и хранения библиографических данных позволяет осуществлять контроль корректности записей на уровне проверки XML-документа. В докладе рассматривается роль XML и перспективы его использования в библиотечно-информационных системах, а также применительно к основным функциям информационных систем – хранению, поиску, представлению и передаче данных.

The recent rapid development of XML-technologies, and advance of software products for XML-format data enables standard coding of document contents while providing flexibility of data organization, and compatibility with hardware & software platforms. The hierarchical structure of bibliographic records conforms with XML-document model. Using XML – format for bibliographic data exchange and storage enables record correctness control records at the stage of XML-document checking. The role of XML and prospects for of its use in library and information systems, and also with reference to the basic functions of information systems – to storage, search, browse and data transmission is considered.

Бурхливий розвиток останнім часом Xml-Технологій, а також збільшення кількості програмних продуктів, що оперують із даними у форматі XML, надає стандартну можливість кодування змісту інформаційних документів, забезпечуючи при цьому гнучкість у створенні структур даних, можливість перенесення на різні апаратно-програмні платформи. Ієрархічна структура бібліографічного запису добре узгодиться з моделлю XML- документа. Використання XML у якості формату обміну та зберігання бібліографічних даних дозволяє здійснювати контроль коректності записів на рівні перевірки Xml-Документа. У доповіді розглянуто роль XML та перспективи його використання в бібліотечно-інформаційних системах, а також відносно основних функцій інформаційних систем – зберігання, пошуку, подання та передачі даних.

Информационно-библиотечные системы, используемые в настоящее время в российском библиотечном сообществе основаны на различных СУБД, основу которых, в той или иной степени, составляют файлы в структуре стандарта ISO-2709 или подобных ему [1]. Кроме этого, структура ISO-2709 лежит в основе таких обменных форматов для библиографических данных, как MARC21 [2], UNIMARC [3], RUSMARC [4] и др. Широкое использование стандарта ISO-2709 в библиотечной практике обусловлено исторически. В связи с бурным развитием информационных и web технологий в последние годы, делает малооправданным использование форматов на основе ISO-2709, несмотря на его широкое распространение. Ряд его существенных недостатков, например, ограничение на длину, уровень иерархии и сложночитаемость становятся все более заметнее для пользователя.

С другой стороны, можно сказать, что наиболее перспективным и универсальным средством для представления структурированных данных в настоящее время является язык XML [5-9]. С момента своего появления язык XML зарекомендовал себя с самой лучшей стороны, поэтому довольно быстро получил широкое распространение. Он оказался чрезвычайно полезной технологией, а по сравнению с ISO-2709 язык XML имеет ряд очевидных преимуществ. Иерархическая структура библиографической записи хорошо согласуется с моделью XML-документа. Использование XML в качестве формата обмена и хранения библиографических данных позволяет осуществлять контроль корректности записей на уровне проверки XML-документа. В отличие от формата ISO-2709, XML – это легко читаемый формат для пользователя и легко документируемый, а также в нем отсутствуют ограничения на длину документа. В отличие от ISO-2709 и разнообразием MARC-форматов, порожденных на его основе, XML более динамичен и позволяет легко порождать новые схемы данных и правила перехода между ними, которые формулируются на том же самом языке (XSLT – преобразования), а также поддерживается большим количеством производителей программного обеспечения. В стандарт XML включена поддержка кодировок Unicode, что упрощает создание многоязычных документов. Кроме этого следует заметить, что ISO-2709 в отличие от XML не предусматривает передачу двоичных данных, таких как графическое изображение или аудио- или видеоматериалы, без которых сегодня немыслима информационная среда. Особо важным достоинством языка XML является его интеграция с web-средой, а также платформенная независимость. Все это де-факто делает XML стандартом для обмена данными.

Таким образом, очевидна актуальность проблемы взаимного преобразования данных в форматах ISO-2709 и XML. В настоящее время предприняты попытки построения MARC – XML – конвертеров (парсеров), известно несколько разработок европейских и американских университетов и библиотек [10-11]. Наиболее удачными, на наш взгляд, являются конвертеры Стэнфордского университета и ЮНЕСКО. Но большая часть из представленных в сети Интернет программных продуктов не позволяет преобразовывать данные в процессе конвертирования. Однако для полноценной работы с документом необходимо иметь разнообразные способы отображения как документа целиком, так и его частей. Данные, содержащиеся в библиографической записи, могут быть использованы, например, для формирования карточки библиографического описания, требования для заказа книги в библиотеке, а также для изменения или добавления новой записи. Таким образом, чтобы получить запись в нужном представлении в формате XML, во-первых, необходимо воспользоваться парсером для формата ISO-2709, и только после этого возможно применять предлагаемые конвертеры. Кроме этого, можно отметить такие недостатки представленных программных продуктов, как работа только с конкретным вариантом MARC-формата и отсутствие поддержки кириллицы.

Следует заметить, что существующая практика представления библиографических записей в формате XML, основано на эмуляции структур ISO-2709 средствами XML, является половинчатым решением, в рамках которого невозможно использовать все достоинства XML-технологии. Иными словами, проблема не решается, а, образно говоря, прячется за красивые слова об XML. В качестве иллюстрации ограничения, используемых подходов можно сказать, что структура описания документа наследуется полностью и остается двухуровневой. В качестве различных интерпретаций XML-представлений ISO-2709 записей можно привести следующие эмуляции записей: SimpleXML, OAI, MarcXML, XChange и др. (см. <http://z3950.nsc.ru:210>).

На наш взгляд, более перспективным применением XML-технологий для представления библиографических записей является применение схем данных, не связанных с ISO-2709. В качестве

примера такой схемы может выступать схема MODS (<http://www.loc.gov/mods>), однако ее применение потребует изменения правил каталогизации и дополнительной стандартизации библиографических описаний, отличных от идеологии MARC-форматов и в будущем именно эти технологии будут занимать лидирующее место.

Наряду со средствами преобразования, следует отметить полезное ПО для создания и редактирования XML документов в принципе достаточно самого простого текстового редактора, однако разработаны и существуют более «продвинутые» XML – редакторы, например, XED, XML Notepad, VisualXML и др. [12-14]. Для анализа и разбора (проверки корректности и/или состоятельности) XML документов доступны следующие анализаторы: XP, AElfired и др. [15-16].

После преобразования записи во внутренний формат происходит изменение представления данных согласно таблице выбора полей. (Именно возможность этого изменения и отличает данное приложение от программных продуктов данного класса, имеющих в свободном доступе). После завершения внутреннего форматирования происходит создание XML-элементов с учетом названий тегов, представленных в таблице определения полей. Настоящее приложение позволяет получать конечные данные не только в формате XML, но и в формате ISO-2709.

В настоящее время авторами ведутся работы по разработке XML-сервера библиографических БД, позволяющего осуществлять полнофункциональную обработку библиографических данных, представленных в формате XML. Следует отметить, что основная цель данной работы заключается не в детальном рассмотрении MARC-форматов и XML-технологий, а в том, чтобы подчеркнуть актуальность проблемы преобразования данных между форматами ISO-2709 и XML.

В заключение отметим, что переход на XML стандарт описания библиографической информации позволит независимым пользователям, использующим различные аппаратно-программные платформы легко использовать информацию, получаемую друг у друга, поскольку документы XML можно использовать как минимум в двух ипостасях: во-первых, как информацию для восприятия человеком и, во-вторых, как данные для обработки приложениями.

Литература

1. International Organization for Standardization. Documentation: format for bibliographic information interchange on magnetic tape. [2 ed.] Geneva, ISO, 1981 (ISO 2709-1981). The first edition was published in 1973.
2. Форматы USMARC. Краткое описание: В 3-х ч. М.: ГПНТБ России. – 1996.
3. Руководство по UNIMARC: Руководство по применению международного коммуникативного формата UNIMARC. – М.: ГПНТБ России. – 1992. – 320 с.
4. Российский коммуникативный формат представления библиографических записей в машиночитаемой форме: (Российский вариант UNIMARC). СПб.: Изд-во РНБ. – 1998.
5. Основные положения формата MARC для библиографических данных. / Под общей редакцией действительного члена постоянного Комитета по UNIMARC Я. Л. Шрайберга. ГПНТБ России. – М., 1997. – 39 с.
6. Питц-Моултис Н., Кирк Ч. XML: Пер. с англ. – СПб.: БХВ-Петербург. – 2000. – 736 с.
7. Валиков А. Н. Технология XSLT. СПб.: БХВ-Петербург, 2002
8. Грейвс М. Проектирование баз данных на основе XML. М: Издательский дом «Вильямс», 2002
9. XML 1. 0 (Second Edition) – <http://www.w3.org/TR/2000/REC-xml-20001006>
10. Конвертер MARC-записей в XML-документы <http://xmlmarc.stanford.edu/>
11. Конвертер UNESCO <http://www.unesco.org/webworld/isis/xml2isis.htm/>
12. XED www.ltd.ed.ac.uk/~ht/xed.html
13. XML Notepad www.microsoft.com/xml
14. VisualXML www.pierlou.com
15. XP www.jclark.com
16. AElfired www.microstar.com