

# Разработка семантических электронных библиотек на основе онтологических моделей

© Ле Хоай,

© А.Ф Тузовский

Национальный исследовательский Томский политехнический университет

Оптимизация систем управления, Институт кибернетики.

lehotomsk@yahoo.com, tuzovskyaf@tpu.ru

**Аннотация.** Рассматриваются основные функции электронных библиотек на основе использования семантических технологий, делается постановка задач их реализации. Предлагаются методы их решения и демонстрируются примеры реализации функций семантической электронной библиотеки в разработанной системе.

## 1 Введение

Под электронными библиотеками (ЭБ) понимаются информационные системы, позволяющие автоматизировать работу пользователей с различными электронными ресурсами: документами, изображениями, мультимедиа-файлами. Реализация подобных систем сталкивается с рядом ключевых проблем [1]:

- интеграция разнородной информации (электронных ресурсов, пользовательских профилей, структур знаний предметных областей), представленной разными способами на основе использования различных метаданных;

- обеспечение надёжности результатов поиска и навигации по ресурсам;

- обеспечение точности категоризации электронных ресурсов.

Основной причиной возникновения этих проблем является описание электронных ресурсов (ЭР) в системе в виде набора терминов естественных языков (ключевых слов) и формирование логических выводов об их смысловом содержании без учёта синонимии, полисемии и омонимии. Это влечёт за собой снижение качества функций, предоставляемых ЭБ.

Для решения перечисленных проблем и повышения эффективности работы с ЭР требуется выполнять работу с их семантикой, для чего используются модели описания семантики (таксономии, тезаурусы, онтологии) и технологии Semantic Web (семантические технологии). Использование таких технологий позволяет реализовать работу с ЭР на новом уровне, с учётом содержащегося в них смысла. Электронные библиотеки, разработанные с использованием подобных технологий, обычно называются семантическими ЭБ (СЭБ).

В данной статье предлагается способ реализации

основных функций СЭБ, таких как: семантический поиск, формирование рекомендаций, выполнение навигации по ресурсам и автоматическая категоризация.

## 2 Онтологический подход к описанию ЭР

Основной идеей данного подхода является использование онтологий предметных областей для аннотирования содержания электронных ресурсов [2]–[4]. В СЭБ описание электронных ресурсов, содержащих знания из разных предметных областей, выполняется с использованием специально разработанных онтологий этих областей, описанных с помощью таких языков, как RDFS или OWL [5],[6].

Под описанием (аннотированием) ресурса понимается его семантическое метаописание, в виде набора простых высказываний (триплетов) на основе онтологической модели, в состав которых могут входить контекстные и контентные семантические метаданные.

Сделаем вначале несколько базовых определений.

**Определение 1.** Под онтологической моделью (онтологией)  $O$  понимается знаковая система  $\langle C, P, I, L, T \rangle$ , где  $C$  – множество элементов, которые называются понятиями;  $P$  – множество элементов, называемые свойствами (двуместными предикатами);  $I$  – множество экземпляров понятий;  $L$  – множество текстовых меток или значений понятий и свойств;  $T$  – частичный порядок на множестве  $C$  и  $P$ .

С помощью набора предикатов  $P$  онтологии могут описываться различные отношения между понятиями и экземплярами. Эти отношения задаются с использованием простых утверждений (триплетов)  $\langle s, p, o \rangle$ , где  $s$  и  $o$  – это субъект и объект высказывания, а  $p \in P$  – это предикат онтологии  $O$ .

Считаем, что любому свойству  $p \in P$  может быть задан весовой коэффициент (семантический вес)  $pv \in [0, 1]$ , задающий смысловую близость между субъектом и объектом утверждения (1 – субъект и объект считаются сходными по семантике, а 0 – не похожими), составленного с использованием данного свойства.

**Определение 2.** Контекстными метаданными ресурса  $s$  (заданного с помощью идентификатора

URI) называется набор простых утверждений (триплетов)  $M_k = \{t_i = \langle s, p_i, o_i \rangle \mid i = 1, n\}$ , где  $s \in I$  – это аннотируемый ресурс (субъект),  $o \in C \cup I \cup L$  – объект утверждения,  $p \in P$  – отношение между субъектом и объектом.

Таким образом, под набором  $M_k$  ресурса  $s$  в СЭБ понимаются утверждения о его связи с другими объектами, понятиями из общих онтологий библиотеки, таких как онтологии пользователей, онтологии ресурсов и онтологии предметных областей.

**Определение 3.** *Контентные метаданные ресурса – это набор простых утверждений (кортежей)  $M_c = \{t_j = \langle s_j, p_j, o_j, v_j \rangle \mid j = 1, m\}$ , где  $s \in C \cup I$  – это субъект утверждения,  $o \in C \cup I$  – объект утверждения,  $p \in P$  – отношение между субъектом и объектом, а  $v$  – весовой коэффициент, который оценивает значимость данного утверждения.*

Под набором  $M_c$  ресурса  $s$  понимаются утверждения о знаниях, содержащихся в самом аннотируемом ресурсе.

В СЭБ набор  $M(s) = M_k(s) \cup M_c(s)$  будет называться семантическими метаданными ресурса  $s$ . Таким образом, все компоненты библиотеки (электронные ресурсы, пользователи, категории и т.п.) описываются метаданными, представленными с помощью RDF-триплетов на основе использования элементов некоторых онтологий. Множество триплетов, описывающих онтологию  $O$  и их экземпляры  $s$ , формирует базу знаний (БЗ, Knowledge Base) СЭБ. К этой базе знаний могут выполняться запросы, описанные на некотором языке (например, SPARQL или SERQL [8], [9]), и на основе их обработки могут решаться различные задачи, позволяющие реализовать услуги, предоставляемые СЭБ.

### 3 Постановка задач и их решение

Доступные функции СЭБ (семантический поиск, категоризация и формирование рекомендаций) реализуются с учетом семантики описаний ЭР. В связи с этим необходима некоторая оценка (метрика) семантической близости различных объектов.

#### 3.1 Семантическая близость

Семантическая близость (смысловое сходство) может определяться между разными компонентами триплетов, триплетами и наборами триплетов. Существуют различные методы вычисления таких метрик [4], которые имеют свои сильные и слабые стороны. В рамках данной работы они не анализируются. В ходе выполнения исследований по созданию СЭБ авторами были разработаны новые методы оценки семантической близости, учитывающие специфику разрабатываемой системы.

#### 3.1.1 Метод вычисления семантической близости между компонентами триплетов

Пусть  $\text{Sim}(\alpha, \beta)$  – семантическая близость между элементами  $\alpha$  и  $\beta$ , где  $\alpha, \beta \in C \cup I \cup P \cup T$ . Для вычисления  $\text{Sim}(\alpha, \beta)$  необходимо построить неориентированный граф  $GO$  из всех имеющих триплетов в БЗ. Граф  $GO$  создаётся в соответствии со следующими правилами:

- используются только триплеты, у которых значения весовых коэффициентов предикатов не равны нулю ( $pv \neq 0$ );

- вершинами графа являются субъекты и объекты триплетов, а ребра графа, соединяющие субъекты с объектами имеют веса, равные значению  $pv$  предиката того триплета, с использованием которого они были сформированы;

- инверсное отношение (на основе предиката `owl:inverseOf`) между предикатами  $p1$  ( $pv1$ ) и  $p2$  ( $pv2$ ) добавляет в граф два ребра с весами  $pv1$  и  $pv2$ , например: для триплета  $\langle s, p1, o \rangle$  добавляются следующие два ребра:  $\langle s, pv1, o \rangle, \langle o, pv2, s \rangle$ ;

- симметричное отношение добавляет в граф два ребра с равными весами, например: `<owl:sameAs>` добавляет два ребра со значениями  $pv = 1.0$ .

Под путём  $\text{PATH}(\alpha, \beta)$  между двумя вершинами  $\alpha$  и  $\beta$  графа  $GO$  понимается набор рёбер (предикатов) ведущих от вершины  $\alpha$  до вершины  $\beta$ , с учётом их направленности. В этом случае значение  $\text{Sim}(\alpha, \beta)$  между этими вершинами вычисляется следующим образом:

$$\text{Sim}(\alpha, \beta) = \max_{i=1 \rightarrow k} (\text{Sim}_{\text{PATH}_i}(\alpha, \beta)), \quad (1)$$

где  $k$  – число возможных путей графа  $GO$  от вершины  $\alpha$  до вершины  $\beta$ . Значение семантической близости между элементами  $\alpha$  и  $\beta$  по направлению пути  $i$   $\text{Sim}_{\text{PATH}_i}(\alpha, \beta)$  определяется по следующей формуле:

$$\text{Sim}_{\text{PATH}_i}(\alpha, \beta) = \prod_{j=1}^{h_i} pv_{i,j}, \quad (2)$$

где  $h_i$  – число семантических отношений между элементами  $\alpha$  и  $\beta$  на пути  $i$ ,  $pv_{i,j}$  – значение веса ребра на основе  $j$ -ого семантического предиката на пути  $i$ . На основе формул 1 и 2 можно получить окончательную формулу для определения семантической близости между вершинами  $\alpha$  и  $\beta$ :

$$\text{Sim}(\alpha, \beta) = \max_{i=1 \rightarrow k} (\text{Sim}_{\text{PATH}_i}(\alpha, \beta)) = \max_{i=1 \rightarrow k} \left( \prod_{j=1}^{h_i} pv_{i,j} \right) \quad (3)$$

Величина  $\text{Sim}(\alpha, \beta)$  удовлетворяет следующим свойствам:  $\text{Sim}(\alpha, \beta) \in [0,1]$ ;  $\text{Sim}(\alpha, \beta) = 0$  при отсутствии пути от  $\alpha$  к  $\beta$ ;  $\text{Sim}(\alpha, \alpha) = \text{Sim}(\beta, \beta) = 1$ . В исключительном случае  $\text{Sim}(\alpha, \beta)$  может равняться 1, при условии существования инверсного отношения между элементами  $\alpha, \beta$ .

#### 3.1.2 Метод вычисления семантической близости между триплетами

Пусть  $\text{Sim}(t_1, t_2)$  – семантическая близость между триплетом  $t_1$  и  $t_2$ . Близость между триплетом вычисляется на основе близостей между их компонентами. В данной работе учитываются свойства инверсного отношения между предикатами (Если два предиката  $p_1$  и  $p_2$  имеют отношение  $\langle p_1, owl:inverseOf, p_2 \rangle$ , то при наличии триплета  $\langle s, p_1, o \rangle$  подразумевается триплет  $\langle o, p_2, s \rangle$ ) [7].

Имеются следующие две ситуации:

- если  $t_1, t_2 \in Mk$ : то  $\text{Sim}(t_1, t_2)$  вычисляется по следующей формуле:

$$\text{Sim}(t_1, t_2) = \text{Sim}(p_1, p_2) \times \text{Sim}(o_1, o_2) \quad (4)$$

- если  $t_1, t_2 \in Mc$ : то  $\text{Sim}(t_1, t_2)$  определяется следующим образом:

$$\text{Sim}(t_1, t_2) = \begin{cases} |k| \frac{\text{Sim}(s_1, s_2) + \text{Sim}(o_1, o_2)}{2} \omega(t_1, t_2), \forall k > 0 \\ |k| \frac{\text{Sim}(s_1, o_2) + \text{Sim}(o_1, s_2)}{2} \omega(t_1, t_2), \forall k \leq 0 \end{cases}, \quad (5)$$

где  $\omega(t_1, t_2) = v_1 \times v_2$  – функция весовых коэффициентов значимости двух триплетов;  $k = \text{Sim}(p_1, p_2)$  и  $\text{Sim}(t_1, t_2) \in [0, 1]$ ;  $\text{Sim}(t_1, t_2) = 0$  при  $k = 0$ .  $\text{Sim}(p_1, p_2)$  также вычисляется по формуле 3.

### 3.1.3 Метод вычисления семантической близости между наборами триплетов

Семантическая близость между наборами триплетов может быть вычислена с использованием двух методов: на основе метода предложенного в работе [10] и метода косинусной меры в модели векторного пространства [11]. Для вычисления семантической близости между наборами триплетов  $T_1 = \{t_i = \langle s_i, p_i, o_i \rangle \mid i = 1, k\}$  и  $T_2 = \{t_j = \langle s_j, p_j, o_j \rangle \mid j = 1, h\}$  используются следующие формулы:

$$\text{Sim}(T_1, T_2) = \frac{\sum_{t_i \in T_1} \max(\text{Sim}(t_i, T_2))}{|T_1|} \quad (6)$$

$$= \frac{\sum_{i=1}^k \max_{j=1 \rightarrow h}(\text{Sim}(t_i, t_j))}{k} \text{ и}$$

$$\text{Sim}(T_1, T_2) = \frac{T_1 \times T_2}{\sqrt{T_1^2} \times \sqrt{T_2^2}} =$$

$$\frac{\sum_{i=1}^k \sum_{j=1}^h \text{Sim}(t_i, t_j)}{\sqrt{\sum_{i=1}^k \sum_{j=1}^k \text{Sim}(t_i, t_j) \times \sum_{i=1}^h \sum_{j=1}^h \text{Sim}(t_i, t_j)}}, \quad (7)$$

где  $\text{Sim}(T_1, T_2) \in [0, 1]$  и  $\text{Sim}(t_i, t_j)$  – семантическая близость между триплетом, вычисляемая по формуле 4 (если  $\forall t_i, t_j \in Mk$ ) или формуле 5 (если  $\forall t_i, t_j \in Mc$ ).

### 3.2 Семантический поиск

Как отмечалось ранее, метаописание ЭР на основе онтологической модели  $O$  рассматривается с точки зрения его контекста и контента. На основе

контекстных метаданных и контентных метаданных, запрос семантического поиска  $q$  представляется в виде набора  $M(q) = (Mk(q), Mc(q))$ , а объект кандидата  $d$  (возможный результат на данный запрос) –  $M(d) = (Mk(d), Mc(d))$ . Тогда, задачу семантического поиска можно переформулировать следующим образом: Имеется запрос  $q$  с его набором  $M(q)$ , тогда результатом выполнения данного запроса  $q$  будет конечный набор из  $k$  объектов знаний (ЭР)  $D = \{d_i \mid i = 1, k\}$ , где каждый  $d$  с набором  $M(d)$  удовлетворяет следующему условию:

$$\text{Sim}(M(q), M(d)) = \alpha \times \text{Sim}(Mk(q), Mk(d)) + \beta \times \text{Sim}(Mc(q), Mc(d)) > \varepsilon, \quad (8)$$

где  $\varepsilon \in (0, 1)$  – пороговое значение,  $\alpha$  и  $\beta$  – коэффициенты близости по контексту и по контенту, соответственно и  $\alpha + \beta = 1.0$ . Значения  $\alpha$  и  $\beta$  настраиваются так, чтобы значение семантической близости корректно определяло важность контента и контекста искомого объекта. Если более важным является содержание искомого объекта (контента), тогда значение  $\beta$  превышает значение  $\alpha$  и наоборот.

Кроме семантического поиска, в СЭБ также доступен и поиск по графу, который получает широкое применение в социальных сетях (например: *Facebook*) [13].

### 3.3 Формирование рекомендаций

В данной работе под формированием рекомендаций понимается предоставление пользователям набора ресурсов, релевантных рассматриваемому ЭР. Пусть в СЭБ имеется ЭР  $d$  с метаданными  $M(d) = (Mk(d), Mc(d))$ . Задача формирования рекомендаций для документа  $d$  может рассматриваться как выполнение семантического поиска с использованием запроса  $q = d$  с наборами  $Mk(d)$  и  $Mc(d)$ . Набор кандидатов  $R = \{dr_i \mid dr_i \neq d \wedge i = 1, h\}$  на запрос  $q$  считаются рекомендуемыми для документа  $d$  если для любого  $dr \in R$  выполняется условие:

$$\alpha \times \text{Sim}(Mk(d), Mk(dr)) + \beta \times \text{Sim}(Mc(d), Mc(dr)) > \varepsilon \quad (12)$$

Выборы значений  $\alpha$ ,  $\beta$  и порогового значения  $\varepsilon$  делаются вручную или автоматически на основе количества триплетов метаописаний ресурса  $d$ .

### 3.4 Автоматическая категоризация

В СЭБ пользователь может создавать свои категории (рубрики), а система автоматически будет относить релевантные ресурсы к заданным категориям. Одна категория может включить в себя другие категории, и они структурируются в виде какой-либо иерархии (например: категория – подкатегория).

Категория  $k$  может описываться конечным набором шаблонных ресурсов  $Dk = \{tr_i \mid i = 1, h\}$  и каждый  $tr_i$  имеет своё метаописание  $M(tr_i)$ . Любой ресурс  $dr \notin Dk$  считается релевантным к заданной категории  $k$  при выполнении следующего условия:



Рис. 1. Программная архитектура системы SemDL

$$\alpha \times \text{Sim}(M_k(Dk), M_k(dr)) + \beta \times \text{Sim}(M_c(Dk), M_c(dr)) > \varepsilon, \quad (13)$$

где  $M_k(Dk) = M_k(tr1) \cup \dots \cup M_k(trh)$ ,  $M_c(Dk) = M_c(tr1) \cup \dots \cup M_c(trh)$ . В качестве шаблонных ресурсов могут служить существующие ЭР или наборы триплетов (контекст и контент), созданные вручную для описания созданной категории. Кроме метода категоризации по набору шаблонных ресурсов в СЭБ выполняется категоризация по элементам используемых в СЭБ онтологий, описывающих предметные области.

### 3.5 Метод просмотра

В СЭБ все ЭР (экземпляры), понятия (элементы) онтологии (кроме лексических и числовых данных) имеют уникальные идентификаторы (*URIs*). Такими идентификаторами могут быть субъекты, объекты и предикаты триплетов в БЗ. В связи с этим имеется возможность просмотра содержания СЭБ по субъектам или объектам описаний ЭР. Реализация функции просмотра позволяет пользователям находить и просматривать все допустимые отношения (триплеты), связанные с рассматриваемым ресурсом. Например: по ссылке автора ресурса, можно найти все его публикации, его интересы и т.п., а далее по этим публикациям и интересам могут быть выполнены следующие переходы.

## 4 Программная реализация в SemDL

Предложенные методы решения задач по реализации описываемых функций СЭБ применены в разработанной системе *SemDL* [10].

### 4.1 Программная архитектура SemDL

Программная архитектура системы *SemDL* показана на рис. 1. Она логически разделена на четыре уровня. В соответствии с этим разделением, пользователи взаимодействуют с системой с помощью веб-интерфейса и под контролем системы могут получить доступ к интересующим их функциям системы. Системные компоненты (пакеты) группируются по четырём категориям на основе их функциональности:

- **ПРЕДСТАВЛЕНИЯ (VIEWS)**: включают в себя различные разработанные теги (например, HTML-теги) и сервлеты (*servlets*), которые непосредственно обрабатывают полученные запросы и возвращают ответы системы.

- **АННОТАЦИЯ (ANNOTATION)**: включает функции для работы с текстовыми документами (извлечение, индексирование). В основном, данный пакет выполняет поиска кандидатов для аннотирования ресурсов (создание метаописания ЭР). Индексирование и поиск ключевых слов возлагается на библиотеку с открытым исходным

кодом *LUCENE ENGINE* [14], [15].

• **ГРАФ ОЦЕНОК (WG)**: данный пакет предназначен для создания и индексирования графа семантических оценок *GO*, и вычисляет семантическую близость между компонентами триплетов, наборами триплетов по контенту и контексту. Элементарные операции с графом осуществляется с помощью библиотеки с открытым исходным кодом *JGRAPH* [16]-[18].

• **СЕРВИСЫ SEMDL**: данный пакет осуществляет доступ к базе знаний (*SESAME*) и выполняют различные операции с хранимыми данными, а также обеспечивают фильтрацию ресурсов по наборам триплетов контента и контекста. Для работы с *SESAME* используется библиотека с открытым исходным кодом *OPENRDF-SESAME-API* [19], [20].

#### 4.2 Реализация

Примеры интерфейса системы SemDL показаны на рис. 2–3. Составление запроса с использованием набора триплетов по контексту или контенту для семантического поиска выполняется с помощью рекомендации субъектов, предикатов и объектов на основе вводимых терминов (слов). Результаты поиска, рекомендации или категоризации ранжируются в порядке уменьшения оценок семантической близости. Ресурсы в результатах кратко показываются с основными свойствами (авторы, ключевые слова), по которым можно выполнять переходы к другим ресурсам. При работе с категориями и рекомендациями для получения желаемых результатов можно настраивать значения параметров  $\alpha$ ,  $\beta$  и  $\varepsilon$ . Значения параметров  $\alpha$  и  $\beta$  по умолчанию определяются на основе количества триплетов для описания контекста и контента ресурса.

#### 4.3 Обоснование полученного решения

**Процесс семантического поиска.** Схема процесса выполнения семантического поиска показана на рис. 4. Пользователь выполняет семантический поиск с помощью составленных триплетов контекста и контента  $M(q)$ . На основе  $M(q)$  выполняется фильтрация возможных кандидатов (ЭР)  $d$ , которые могут быть ответом на запрос  $q$ . В результате чего получают наборы:  $S_{PRK}$  – набор возможных кандидатов по контексту и  $S_{PRC}$  – набор по контенту. В дальнейшем между метаописаниями  $M(q)$  и  $M(d)$  вычисляются близости по формуле 8. Ресурсы  $d$ , которые удовлетворяют заданному запросу  $q$ , ранжируются по степени убывания значений их близости обрабатываемому запросу.

**Фильтрация возможных кандидатов.** Для повышения эффективности работы данного алгоритма имеется возможность выполнять фильтрацию возможных кандидатов с использованием описанных ниже методов.

**Метод фильтрации по набору триплетов контекста.** Пусть задан набор триплетов контекста некоторого объекта  $s$ :  $T_K = \{t_i = \langle s, p_i, o_i \rangle \mid i = 1, k\}$ . Для любого элемента  $e$  триплета имеется непустой список связанных элементов по семантике  $Exs$ :  $Exs(e) = \{e, e_i \mid i = 0, h \wedge \text{Sim}(e, e_i) > \varepsilon\}$ , где  $\varepsilon$  – пороговое значение близости и  $\text{Sim}(e, e_i)$  вычисляется по формуле 3.

Пусть  $Exs_P(T_K)$  – список всех предикатов из набора  $T_K$  и их связанных элементов по семантике,  $Exs_P(T_K) = Exs(p_1) \cup \dots \cup Exs(p_k)$ ;  $Exs_O(T_K) = Exs(o_1) \cup \dots \cup Exs(o_k)$  – список всех объектов из набора  $T_K$  и их связанных элементов по семантике.

На основе списков связанных элементов по семантике предложенный метод фильтрации по набору  $T_K$  допускает только тот ресурс  $prk \in S_{PRK}$  с набором триплетов его контекста  $T_{PRK} = \{t_j = \langle prk, p_j, o_j \rangle \mid j \in [1, h]\}$ , который удовлетворяет следующему условию:

$$(\exists t_j \in T_{PRK}) \wedge (p_j \in Exs_P(T_K)) \wedge (o_j \in Exs_O(T_K)) \quad (14)$$

**Метод фильтрации по набору триплетов контента.** Пусть заданный набор триплетов контекста некоторого объекта  $s$ :  $T_C = \{t_i = \langle s_i, p_i, o_i \rangle \mid i = 1, k\}$ . Для набора  $T_C$  имеются следующие списки связанных элементов по семантике для компонентов всех триплетов:  $Exs_S(T_C) = Exs(s_1) \cup \dots \cup Exs(s_k)$ ;  $Exs_P(T_C) = Exs(p_1) \cup \dots \cup Exs(p_k)$ ;  $Exs_O(T_C) = Exs(o_1) \cup \dots \cup Exs(o_k)$ .

На основе списков связанных элементов по семантике предложенный метод фильтрации по набору  $T_C$  допускает только тот ресурс  $prc \in S_{PRC}$  с набором триплетов его контента  $T_{PRC} = \{t_j = \langle s_j, p_j, o_j \rangle \mid j = 1, h\}$ , который удовлетворяет следующему условию:

$$(\exists t_j \in T_{PRC}) \wedge (s_j \in Exs_S(T_C)) \wedge (p_j \in Exs_P(T_C)) \wedge (o_j \in Exs_O(T_C)) \quad (15)$$

Условия фильтрации (14 и 15) могут описываться на языках запросов *SPARQL* или *SERQL*, которые эффективно обрабатываются сервером БЗ.

Пример шаблона запроса на языке *SERQL* для фильтрации возможных кандидатов некоторого объекта  $S$  по заданным наборам триплетов показан ниже.

*/\*Запрос на фильтрацию возможных кандидатов по набору  $T_K$ \*/*

**SELECT S FROM**

**{S} P {O}**

**WHERE P IN Exs\_P( $T_K$ ) AND O IN Exs\_O( $T_K$ )**

**USING NAMESPACE**

**...**

*/\*Запрос на фильтрацию возможных кандидатов по набору  $T_C$ \*/*

*/\* CONTEXT S – триплеты контента объекта S\*/*

**SELECT S FROM CONTEXT S**

**{Sc} Pc {Oc}**

**WHERE Sc IN Exs\_S( $T_C$ ) AND Pc IN Exs\_P( $T_C$ ) AND Oc IN Exs\_O( $T_C$ ) USING NAMESPACE ...**

## Семантический поиск

### Контентные триплеты для поиска

[Ле Хоай, Знает, Тузовский А. Ф.]

ПОИСК Пусто

### Создание триплетов для поиска

Удалить Semantic searches Ключевое слово Тузовс

Контекст  Объект

content search  context search

Добавить

Тузовский А. Ф  
type: Author add

другие результаты [1/1]

### Контекстные триплеты для поиска

Выбор типа искомого объекта Другие Добавить

type Автор Ключевое слово

Документ Ле Хоай Тузовский А. Ф СЭБ Семантические технологии

ПОИСК Пусто

### Результат поиска

11 результатов за 1.03 секунд с установленным порогом:0.1


РАЗРАБОТКА ЭЛЕКТРОННЫХ БИБЛИОТЕК НА ОСНОВЕ СЕМАНТИЧЕСКИХ ТЕХНОЛОГИЙ  
Год:2012 [84.2%]  
Автор:Тузовский А. Ф, Ле Хоай,



Рассматривается ряд проблем в электронных библиотеках, анализируются новые технологии, предоставляющие средства их решения. Появляются семантические электронные библиотеки, их архитектура электронных ресурсов, а также задачи

Ключевые слова:СЭБ, Семантические технологии, Электронная библиотека, Semantic search, Система управления знаниями,  
Домены:

Рис. 2. Составление триплетов для поиска



7 результатов за 0.89 секунд с  $\varepsilon=0.3$

Разработка семантических электронных библиотек Год: [99.0%]  
Автор:Ле Хоай, Тузовский А. Ф,



Рассматривается подход к созданию электронных библиотек и их разработке с использованием семантических технологий. Появляются функции электронных библиотек, для автоматизации которых требуется использовать семантику и

Ключевые слова:Семантические технологии, СЭБ, Электронная библиотека, Semantic search,  
Домены:

Рис. 3. Интерфейс категоризации или рекомендации на основе метаописаний




Рис. 4. Схема процесса семантического поиска

	S	P	O	№
Mк(q)	?S	_:type	_:Document	1
	?S	_:hasKeyword	_:Semantic_Technology	2
	?S	_:hasKeyword	_:Semantic_Digital_Library	3
	?S	_:hasAuthor	_:Ле Хоай	4
	?S	_:hasAuthor	_:Тузовский	5
Количество триплетов контекста (k): 5				
Mк(d)	_:2013051402540193	_:title	РАЗРАБОТКА ЭЛЕКТРОННЫХ БИБЛИОТЕК НА ОСНОВЕ СЕМАНТИЧЕСКИХ ТЕХНОЛОГИЙ	1
	_:2013051402540193	rdf:type	_:Article	2
	_:2013051402540193	_:hasKeyword	_:Semantic_Technology	3
	_:2013051402540193	_:hasKeyword	_:Semantic_Digital_Library	4
	_:2013051402540193	_:hasKeyword	_:Digital_Library	5
	_:2013051402540193	_:hasKeyword	_:Semantic_Search	6
	_:2013051402540193	_:hasKeyword	_:Knowledge_System	7
	_:2013051402540193	_:hasAuthor	_:Ле Хоай	8
	_:2013051402540193	_:hasAuthor	_:Тузовский	9
Количество триплетов контекста (h): 9				

Рис. 5. Пример метаописаний  $q$  и  $d$

**Пример численных вычислений.** Пример вычисления делается для семантического поискового запроса, показанного на рис. 2 и его первого результата. Их метаописания показаны на рис. 5.

Вначале вычисляются близости между  $M(q)$  и  $M(d)$  по формуле 8 где  $\varepsilon = 0.1$   $\alpha = 1$  и  $\beta = 0$ , так как семантический поиск выполняется по контексту.

На следующем шаге значение  $\text{Sim}(M(q), M(d)) = \text{Sim}(M_k(q), M_k(d))$  вычисляется по формуле 6 или 7. и с целью простоты пояснения используется формулы 6. Для заданных  $M_k(q)$  и  $M_k(d)$  значение  $k = 5$  (число триплетов  $M_k(q)$ ), а значение  $h = 9$  (число триплетов  $M_k(d)$ ). Тогда значение  $\text{Sim}(M_k(q), M_k(d))$  вычисляется следующим образом:

$$\text{Sim}(M_k(q), M_k(d)) = \frac{\sum_{t_i \in M_k(q)} \max(\text{Sim}(t_i, M_k(d)))}{|M_k(q)|} = \frac{\sum_{i=1}^5 \max(\text{Sim}(t_i, t_j))}{5} = \frac{\sum_{i=1}^5 \max(\text{Sim}(p_i, p_j) \times \text{Sim}(o_i, o_j))}{5}$$

Для  $i = 1$  и  $j = 1 \rightarrow 8$  величина  $p(q)_1 = \text{rdf:type}$ , а  $p(d)_{1 \rightarrow 8} \in \{ \_:\text{title}, \text{rdf:type}, \_:\text{hasKeyword}, \_:\text{hasAuthor} \}$ . Так как в используемой онтологической модели нет семантических отношений между предикатами  $p(q)_1$  и  $p(d)_{1 \rightarrow 8}$  (но могут быть семантические отношения между другими предикатами), то  $\max(\text{Sim}(t_1, M_k(d))) = \max_{i=1, j=1 \rightarrow 8} (\text{Sim}(p_i, p_j) \times \text{Sim}(o_i, o_j)) = (\text{Sim}(p_1, p_2) \times \text{Sim}(o_1, o_2))$ , так как  $\text{Sim}(p_i, p_j) = 0$  при  $j \neq 2$ .

Тогда в данном случае получается следующая окончательная формула:  $\max(t_1, M_k(d)) = \text{Sim}(\text{rdf:type}, \text{rdf:type}) \times \text{Sim}(\_:\text{Document}, \_:\text{Article}) = \text{Sim}(\_:\text{Document}, \_:\text{Article})$ .

Для  $i = 2$  и  $j = 1 \rightarrow 8$  получаем:  $\max(\text{Sim}(t_2, M_k(d)) = \text{Sim}(\_:\text{Semantic\_Technology}, \_:\text{Semantic\_Technology}) = 1$ .

Аналогичным образом выполняются вычисления и для  $i = 3 \rightarrow 5$ .

В конечном результате значение  $\text{Sim}(M_k(q), M_k(d))$  определяется следующим образом:

$$\text{Sim}(M_k(q), M_k(d)) = \frac{\text{Sim}(\_:\text{Document}, \_:\text{Article}) + 1 + 1 + 1 + 1}{5} = \frac{\text{Sim}(\_:\text{Document}, \_:\text{Article}) + 4}{5}$$

Для определения величины  $\text{Sim}(\_:\text{Document}, \_:\text{Article})$  используется граф семантических отношений  $GO$  (рис. 6). Здесь символы « $\_:$ » обозначают некоторое пространство имен понятий.

В показанном фрагменте графа  $GO$  используются четыре семантических отношений:

*subClassOf* (*nodКласс*), *subPropertyOf* (*ПодСвойство*), *hasBroader* (*Уже*) и *hasNarrower* (*Шире*). Отметим, что все эти предикаты отображают таксономические отношения (на практике могут использоваться и другие предикаты). В таксономической иерархии имеются два отношения, которые либо обобщают (*subClassOf*, *subPropertyOf*, *hasBroader*), либо детализируют (*hasNarrower*) понятия.

Предпочтение всегда отдаётся детализации, это означает, что при поиске некоторого понятия более важными являются те понятия, которые детализуют рассматриваемое понятие. В связи с этим можно задать значения предикатом следующим образом:

- Если предикат  $p$  описывает отношение в направлении детализации, то  $p_v > 0.5$ . Например, в данной работе  $p_v(\text{hasBroader}) = 0.8$ .
- Если предикат  $p$  описывает отношение в направлении обобщения, то  $p_v < 0.5$ . Например, в данной работе  $p_v(\text{hasNarrower}) = 0.4$ .




Рис. 6. Фрагмент графа семантических отношений GO

Все значения веса предикатов могут быть заданы специалистом, поддерживающим работу СЭБ, в соответствии с его пониманием онтологии предметной области.

В рассматриваемом случае  $pv(subClassOf) = 0.7$  в направлении детализации, а в направления обобщения  $pv(subClassOf) = 0.3$ , а это значит, что  $Sim( _:Resource, _:Article) = 0.7$ , а  $Sim( _:Resource; _:Article) = 0.3$  и тогда

$$Sim(M_k(q), M_k(d)) = \frac{Sim( _:Document, _:Article) + 4}{5} = \frac{0,3 * 0,7 + 4}{5} = 0,842.$$

Для контентного семантического поиска процессы вычисления выполняются аналогично. Однако при контентном поиске для вычисления близости между триплетами контента учитывается ещё и близость между субъектами триплетов.

## 5 Заключение

Повышение эффективности электронных библиотек в значительной степени связано с использованием в их работе описания семантики электронных ресурсов. Для создания таких ЭБ требуется решение целого комплекса новых задач. В данной статье предложены методы описания семантики ЭР и вычисления семантической близости, рассмотрена реализация стандартных функций электронных библиотек с их использованием. Выполнение тестирования показало высокие результаты со средними значениями критерий: Точность = 100%, Полнота = 94%.

## Литература

- [1] Тузовский, А. Ф. Разработка семантических электронных библиотек / А. Ф. Тузовский, Х. Х. Ле // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2011 – №. 2 (24) – С. 195–199.
- [2] Ле Х. Х. Разработка электронных библиотек на основе семантических технологий // Научно–технический вестник Поволжья. – Казань, 2012. №. 3. С. 138–145.
- [3] Тузовский А.Ф. Формирование семантических метаданных для объектов системы управления знаниями. //Известия Томского политехнического университета. 2007. Т. 310. №. 3. С. 108 – 112.
- [4] Нгуен, Б. Н. Модели и методы поиска информационных ресурсов с использованием семантических технологий: дис. канд. техн. наук / Нгуен Ба Нгок. – Томск, 2012. – 198с.
- [5] Hendler, A. J. Handbook of Semantic Web Technologies. – Springer, 2011.
- [6] OWL Web Ontology Language Overview // Доступ осуществлен 03.04.2013 по адресу <http://www.w3.org/TR/owl-features/>.
- [7] OWL:inverseOf // Доступ осуществлен 03.04.2013 по адресу <http://www.infowebml.ws/rdf-owl/inverseOf.htm>.
- [8] SPARQL 1.1 Federated Query // Доступ осуществлен 03.04.2013 по адресу <http://www.w3.org/TR/sparql11-federated-query/>.
- [9] System documentation for Sesame 2.x // Доступ осуществлен 03.04.2013 по адресу <http://www.openrdf.org/doc/sesame2/system/>.
- [10] Тузовский, А. Ф. Онтолого-семантические модели в корпоративных системах управления знаниями: дис. д-тр. тех. наук / А. Ф.

Тузовский. – Томск, 2007. – 342с.

- [11] Vector space model // Доступ осуществлен 26.07.2013 по адресу [http://en.wikipedia.org/wiki/Vector\\_space\\_model](http://en.wikipedia.org/wiki/Vector_space_model).
- [12] Хоай, Л. Программная система «SemDL – система управления хранилищем электронных ресурсов с использованием семантических технологий» / Ле Хоай, А.Ф. Тузовский // Свидетельство о государственной регистрации программы для ЭВМ № 2013613266. М.: Федеральная служба по интеллектуальной собственности (Роспатент). – 2013.
- [13] Facebook graph search // Доступ осуществлен 03.04.2013 по адресу [http://en.wikipedia.org/wiki/Facebook\\_Graph\\_Search](http://en.wikipedia.org/wiki/Facebook_Graph_Search).
- [14] Thomas Paul. The Lucene Search Engine // Доступ осуществлен 12.05.2013 по адресу <http://www.javaranch.com/journal/2004/04/Lucene.html>.
- [15] Welcome to Apache Lucene // Доступ осуществлен 12.05.2013 по адресу <http://lucene.apache.org/>.
- [16] Java Graph Visualization Library // Доступ осуществлен 12.05.2013 по адресу <http://www.jgraph.com/jgraph.html>.
- [17] JGraph Diagram Component // Доступ осуществлен 12.05.2013 по адресу <http://sourceforge.net/projects/jgraph/>.
- [18] JGraphT Visualizations via JGraph // Доступ осуществлен 12.05.2013 по адресу <http://jgrapht.org/visualizations.html>.
- [19] The Sesame API // Доступ осуществлен 12.05.2013 по адресу <http://www.openrdf.org/doc/sesame/users/ch07.html>.
- [20] Sesame distribution // Доступ осуществлен 12.05.2013 по адресу <http://sourceforge.net/projects/sesame/files/Sesame%20/>.