

Являются ли сайты конференций RCDL научными веб-коммуникаторами?*

© А.А. Печников, Н.Б. Луговая

Институт прикладных математических исследований КарНЦ РАН
{pechnikov, nataly}@krc.karelia.ru

Аннотация

В авторской терминологии модель, называемая схемой научного Веба, конструируется из четырех основных компонент, являющихся непересекающимися подмножествами научных сайтов. Эти компоненты называются административным каркасом, научным подмножеством, ближайшей окрестностью и веб-коммуникатором. При всей кажущейся очевидности того факта, что сайты научных конференций являются средством коммуникации ученых, проведенные исследования показывают, что сайты конференций RCDL веб-коммуникаторами не являются.

1 Схема научного Веба

К актуальным направлениям вебометрики [1], - одного из развивающихся направлений информатики, - относятся исследования гиперссылок (аналогичные термины – «ссылка», «веб-ссылка»), являющиеся единственным способом взаимодействия между сайтами. Практическая применимость этих исследований успешно демонстрируется реализацией алгоритмов информационного поиска таких популярных систем, как Google и Яндекс [2,4]. Теоретические исследования показывают, что изучение гиперссылок имеет достаточный потенциал как в смысле новых источников информации и коммуникации, так и ценности самих веб-страниц [3-6].

В 2008 году в Институте прикладных математических исследований КарНЦ РАН началась работа по проекту «Вебометрические исследования научных интернет-ресурсов российского Интернета». В рамках проекта разработаны поисковый робот для сбора исходящих с сайтов гиперссылок (LPR – аббревиатура от Link, Page и Robot) и база данных, предназначенная для их хранения и обработки (БД ВГ – База Данных

Внешних Гиперссылок). Программный комплекс, состоящий из LPR и БД ВГ, создан на языке PHP, работает под управлением веб-сервера Apache с интегрированным модулем PHP и СУБД MySQL и находится в стадии постоянного совершенствования.

Информацию о ходе проекта можно найти на сайте «Вебометрика. ИПМИ КарНЦ РАН» [7]. По данным на март 2009 года (именно на этих данных основан дальнейший материал), проведено сканирование 280 официальных сайтов организаций и учреждений. Российской академии наук (РАН). Обработано более миллиона html-страниц, найдено и сохранено 660000 различных внешних ссылок, из которых 81000 уникальных.

В результате проведенных исследований построена теоретико-графовая модель множества научных сайтов Рунета, получившая название схемы научного Веба. Схема научного Веба представляет собой ориентированный граф, множество вершин которого соответствует исследуемым сайтам, а дуги отражают гиперссылки, существующие между сайтами (считается, что дуга существует тогда и только когда, существует хотя бы одна гиперссылка с одного сайта на другой).

Показано, что в схеме научного Веба можно выделить четыре компонента.

Первая из них, – административный каркас, – отражает ссылки между сайтами, соответствующие иерархической подчиненности организаций.

Вторая, – множество научных подмножеств, где научное подмножество представляет связи между сайтами родственных организаций.

Третья компонента - это множество ближайших окрестностей официальных сайтов. Ближайшие окрестности содержат вершины, сайты которых имеют имена $ddd.nnn.ss \in nnn.ss$, где $nnn.ss$ – доменное имя официального сайта.

И, наконец, четвертая компонента называется множеством научных веб-коммуникаторов и соответствует множеству сайтов, выполняющих коммуникационные функции между официальными научными сайтами, то есть научные сайты имеют много входящих ссылок с сайтов этого множества и много исходящих ссылок на них.

Веб-коммуникаторы, в свою очередь, можно классифицировать по трем типам как «посредник», «индуктор» и «коммутатор». Краткое описание

Труды 11^й Всероссийской научной конференции «Электронные библиотеки: перспективные методы и технологии, электронные коллекции» - RCDL'2009, Петрозаводск, Россия, 2009.

посредника - «много входящих ссылок, много исходящих ссылок», коммутатора – «мало входящих, много исходящих», а индуктора – «много входящих, мало исходящих».

Упрощенный вариант схемы научного Веба изображен на рис. 1.




Рис.1 Схема научного Веба.

2 Цель и целевое множество исследования

Основной вопрос данной публикации заключается в следующем: являются ли сайты научных конференций научными веб-коммуникаторами?

В качестве объекта исследования были взяты хорошо знакомые авторам конференции «Электронные библиотеки: перспективные методы и технологии, электронные коллекции» (английская аббревиатура – RCDL).

Исследования проводились на множестве сайтов конференций RCDL и научных организаций РАН, являющихся организаторами этих конференций, а также сайтов поддерживающих организаций. Сведения о веб-ресурсах всех 11 конференций приведены на сайте [10], являющемся общим сайтом RCDL и также включенным в число исследуемых сайтов. С помощью LPR было проведено сканирование 10 сайтов конференций из 12. Исключениями являются ресурсы «RCDL 2000: Протвино» и «RCDL 2003: Санкт-Петербург», поскольку они представлены не отдельными сайтами, а директориями на сайтах других организаций (LPR «не умеет» сканировать с произвольной страницы сайта).

Список всех учреждений и организаций РАН, представители которых хотя бы один раз входили в состав организационного или программного комитета, содержит 22 наименования учреждений РАН. По ряду причин (отсутствие сайта, отсутствие на сегодняшний день самой организации и др.) нам пришлось ограничиться 16 сайтами. Список составлен на основе информации, представленной на сайтах конференций и приведен ниже (рис. 2).

Единственной организацией, не входящей в состав РАН, регулярно поддерживающей

конференции, является Российский фонд фундаментальных исследований, сайт которого также включен в исследуемое множество.

3 Результаты исследования

Операция БД ВГ, которая называется ПОСТРОЕНИЕ МАТРИЦЫ, позволяет построить матрицу смежности для 16 сайтов учреждений и организаций РАН; матрица приведена на рис. 2. Элемент матрицы $(i,j)=1$, если существует хотя бы одна гиперссылка с сайта i на сайт j , и $(i,j)=0$ в ином случае.

Соответствие номеров вершин матрицы и организаций:

- | | |
|----|---|
| 0 | Библиотека по естественным наукам РАН |
| 1 | Дальневосточное отделение РАН |
| 2 | Карельский научный центр |
| 3 | Вычислительный центр имени А.А. Дородницына РАН |
| 4 | Институт астрономии РАН |
| 5 | Институт вычислительных технологий СО РАН |
| 6 | Институт космических исследований РАН |
| 7 | Институт математических проблем биологии РАН |
| 8 | Институт прикладной математики им. М. В. Келдыша РАН |
| 9 | Институт прикладных математических исследований КарНЦ РАН |
| 10 | Институт проблем информатики РАН |
| 11 | Институт систем информатики им. А.П. Ершова СО РАН |
| 12 | Институт химической физики им. Н.Н. Семенова РАН |
| 13 | Институт цитологии и генетики СО РАН |
| 14 | Объединенный институт геологии, геофизики и минералогии |
| 15 | Специальная астрофизическая обсерватория РАН |

Определяя силу связности научного подмножества сайтов CFC (Community Force of Connectivity) как отношение реального количества дуг к потенциально возможному, для построенной матрицы имеем $CFC=0,133$. Если же удалить строки и столбцы с номерами 1 и 15 (нулевые), то получаем $CFC=0,205$. Следует сказать, что для академических сайтов это очень высокий показатель (эксперименты с замерами на научных подмножествах, сформированных по различным признакам принадлежности, дают значения в CFC интервале от 0 до 0,35).

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	■		1	1	1			1	1				1	1		
1		■														
2			■			1				1						
3	1		1	■												
4	1				■		1	1	1		1					
5				1		■									1	
6			1				■									
7								■	1							
8				1			1		■			1		1		
9			1			1				■						
10	1					1					■					
11						1						■				
12	1												■			
13						1								■		
14						1									■	
15																■

Рис. 2. Матрица смежности веб-графа сайтов организаторов конференций RCDL.

На фоне такого хорошего результата тем более удивительными выглядит картина гиперссылок с сайтов конференций на сайты организаторов выбранного нами множества (и наоборот), приведенная в табл. 1.

Конференция	Ссылки на организаторов	Ссылки с организаторов
RCDL:	1	0
RCDL 1999:	0	0
RCDL 2001:	1	2
RCDL 2002:	1	0
RCDL 2003:	1	1
RCDL 2005:	0	2
RCDL 2006:	2	2
RCDL 2007:	2	3
RCDL 2008:	2	3
RCDL 2009:	3	3
ВСЕГО	13	16

Табл. 1. Количество связей между сайтами конференций и организаторов.

В табл.1 значение, равное трем, на пересечении строки с названием «RCDL 2005: Ярославль» и столбцом «Ссылки на организаторов» означает, что с сайта конференции RCDL 2005 существуют три ссылки на различные сайты организаторов конференций (не обязательно данной конференции). Соответственно значение, равное двум, на пересечении строки с названием «RCDL 2005: Ярославль» и столбцом «Ссылки с организаторов» означает, что существуют два сайта организаторов, имеющие ссылки на сайт этой конференции. То есть за 11 лет проведения конференций с сайтов

институтов, сотрудники которых (или хотя бы руководство) не могут не знать об этих конференциях, поставлено всего 16 ссылок. И если можно еще понять отсутствие ссылок на конференцию RCDL 1999: Санкт-Петербург (давно это было!), то отсутствие ссылок на общий сайт не поддается объяснению. Правда, и с основного сайта конференций сделана лишь одна ссылка на организаторов.

После этого вряд ли стоит удивляться, что из остальных академических сайтов (а их 265) ссылки на сайт какой-либо конференции RCDL сделаны лишь с шести. Соответственно, и с сайтов конференций ссылки отсылают лишь к 2 академическим сайтам (из тех же 265).

Интересно заметить, что на сайт РФФИ 13 из 15 сайтов организаторов конференций RCDL содержат гиперссылки (и не по одной, а в среднем по 8), не говоря уже о сайтах самих конференций RCDL.

Не хуже, чем сайты конференций, в качестве веб-коммуникатора для сайтов-организаторов конференции выглядит сайт РОМИП (Российский семинар по Оценке Методов Информационного Поиска) [9], на который сделаны ссылки с 2 сайтов, а он ссылается на 3.

Частичный анализ гиперссылок, сделанных с некоторых сайтов конференций RCDL, позволяет классифицировать исходящие ссылки следующим образом: четверть всех ссылок сделаны на другие сайты конференций RCDL, 17% - на сайт РОМИП, 19% - на сайты, рассказывающие о городах, в которых проводятся конференции, 8% - на Яндекс, 7% - на основного организатора текущей конференции и 5% - на РФФИ.

С помощью средств Google мы проверили, какие же сайты все-таки ссылаются на сайты конференций RCDL, если на них не ссылаются сайты организаций-учредителей из числа институтов РАН. Оказалось, что Google обнаруживает 144 ссылки, из которых 30% приходятся на сайт DELOS an Association for Digital Libraries, 30% - на все сайты RCDL вместе взятые, 10% - сайт Института информационных технологий НАН Азербайджана, по 5% - сайт журнала "Электронные ресурсы в библиотеках" и сайт РОМИП; остальные 15 сайтов с долями меньше 5%.

Заключение

Научные конференции являются коммуникационными площадками для ученых. Проведенные исследования показывают, что сайты конференций RCDL на сегодня с такой ролью справляются не в полной мере. Наверное, на это стоит обратить внимание организаторов конференций и разработчиков соответствующих веб-ресурсов.

Литература

- [1] Almind T., Ingwersen P. Informetric analyses on the World Wide Web: Methodological approaches to "webometrics" // *Journal of Documentation*. 1997. №53 (4). P. 404-426.
- [2] Brin S., Page L. The Anatomy of a large scale hypertextual web search engine // *Computer Networks and ISDN Systems*. 1998. №30 (1-7). P. 107-117.
- [3] Cronin B., Snyder H.W., Rosenbaum H., Martinson A., Callahan E. Invoked on the web // *Journal of the American Society for Information Science*. 1998. №49 (14). P. 1319-1328.
- [4] Flake G. W., Lawrence S., Giles C. L., Coetzee, F. M. Self-organization and identification of web communities // *IEEE Computer*. 2002. №35. P. 66-71.
- [5] Thelwall M. Extracting macroscopic information from web links // *Journal of the American Society for Information Science and Technology*. 2001. №52 (13). P. 1157-1168.
- [6] Thelwall M. What is this link doing here? Beginning a fine-grained process of identifying reasons for academic hyperlink creation // *Information Research*. Vol. 8. №3, April 2003. [Электронный ресурс] - 2003. - Режим доступа: <http://informationr.net/ir/8-3/paper151.html>.
- [7] Вебометрика. Институт прикладных математических исследований КарНЦ РАН. [Электронный ресурс] - 2009. - Режим доступа: <http://webometrics.krc.karelia.ru>.
- [8] Индекс цитирования. [Электронный ресурс] - 2008. - Режим доступа: <http://help.yandex.ru/catalogue/?id=873431>.
- [9] Российский семинар по Оценке Методов Информационного Поиска (РОМИП).

[Электронный ресурс] - 2009. - Режим доступа: <http://gomip.ru>.

- [10] Электронные библиотеки: Перспективные Методы и Технологии, Электронные коллекции. [Электронный ресурс] - 2009. - Режим доступа: <http://www.rcdl.ru>.

Are the RCDL confereenses sites scientific web-communicators?

A.A. Pechnikov, N.B. Lugovaya

In author's terminology the model named the scheme of a scientific Web, is designed from four cores a component which are not crossed subsets of scientific sites. These components are called as an administrative skeleton, the scientific subset, the nearest environs and a web-communicator. At all seeming evidence of that fact that sites of scientific conferences are a communication medium of the scientists, the conducted researches show that sites of conferences RCDL a web-communicators are not.

* Работа выполнена при финансовой поддержке РФФИ (проект № 08-07-00023а)