

И. В. Михайленко, Т. В. Лясникова, Е. М. Гончарова

## О качестве контента в интегрированных системах на примере Карты российской науки

*Рассмотрены типичные ошибки при работе с контентом в интегрированной информационно-аналитической системе агрегации данных о цитированиях «Карта российской науки». Проанализированы причины возникновения ошибок на различных этапах передачи данных от создателя публикации – к системе агрегации данных об индексах цитирования.*

**Ключевые слова:** проект «Карта российской науки», система научного цитирования, процесс получения наукометрических показателей, типы ошибок при работе с контентом.

Проект «Карта российской науки» (КРН) исходно ориентирован на интеграцию информационных ресурсов крупнейших систем научного цитирования, а именно *Web of Science (WoS)*, Российский индекс научного цитирования (РИНЦ) и др. Безусловно, каждая из этих систем имеет свою специфику импорта и обработки данных, свои подходы к классификационным системам, свои поисковые системы, транслитерации имён, фамилий. При обработке конкретных запросов со стороны учёных и специалистов к КРН такая специфика систем цитирования порождает целый ряд вопросов и трудностей. Настоящий доклад посвящён некоторым из них.

В условиях необходимости работы с несколькими различными системами цитирования нас заинтересовал вопрос, насколько абсолютны системы такого рода. Мы задались целью выяснить, могут ли такие системы быть безошибочными. Для этого мы проследили весь путь данных от создания публикации до её отражения в наукометрических показателях автора. Можно предположить, что исследование этого вопроса важно не только для специалистов по работе с наукометрией, но и для конечных пользователей таких данных – учёных, руководителей научных подразделений организаций, а также лиц, принимающих решения в сфере управления наукой.

Для ответа на поставленный вопрос рассмотрим источники данных наукометрических систем, процессы импорта этих данных в системы, а также ошибки, возникающие в ходе технологических операций.

Для начала выявим все технологические операции процесса получения наукометрических показателей (рис.1). Этап 1 – создание статьи (книги) автором. Затем рукопись передаётся в издательство и проходит редакторскую правку – этап 2. После этого издательство передаёт копию публикации – электронную (этап 3а) или печатную (этап 3б) в организацию, являющуюся создателем наукометрических данных. Далее возможны два варианта работы – в зависимости от формата носителя передаваемых данных: они либо пересылаются в электронной форме по Интернету (этап 4а), либо переводятся организацией-получателем в электронный вид (этап 4б). Следующий этап – предварительная обработка входных данных: перевод в нужный формат, установка связей между объектами (этап 5). Затем обработанные данные импортируются в информационную систему (этап 6). Только после этого система рассчитывает собственно наукометрические индексы (этап 7).



**Рис. 1. Процесс создания наукометрических индексов**

На каждом этапе могут возникать различные типы ошибок. Рассмотрим их подробнее.

Первый тип ошибок – опечатки – возникает на тех этапах обработки данных, где участвует человек (1 и 2 этапы). На эту тему написана целая книга [3], в которой рассказывается об опечатках как в книгах, так и в статьях, в том числе и научных.

Ошибки в написании фамилии или организации могут повлиять на индексы публикационной активности. Можно привести такой пример: в публикации [7] один из авторов – Матвейчев Алексей Валерьевич, канд. физ.-мат. наук, сотрудник Института проблем химической физики РАН, в описании статьи в РИНЦ указан как «- Матвейчев А. В.». Операторы системы РИНЦ вручную добавили эту публикацию в список учёного, и ни она, ни её цитирование не пропали. Однако опечатка повлекла за собой другие типы ошибок – в КРН публикация попала с таким же написанием автора, и, конечно, без связи с цитирующей её статьёй. После обращения автора к нам мы сможем включить статью в список публикаций Алексея Валерьевича, но восстановить связь с цитирующей статьёй уже будем не вправе – по лицензионному соглашению с РИНЦ, ограничивающему наши права в редактировании данных. В результате – в КРН отсутствует ссылка, индекс цитирования работ учёного занижен по причине одной опечатки.

Несмотря на урон, приносимый научной репутации, ошибки в показателях систем цитирования – не самые страшные. Встречаются и более серьёзные опечатки – такие как искажение данных в медицинских журналах [4] или в финансовых материалах [5].

Если опечатка допущена в фамилии автора, то в результирующих данных будет невозможно связать реального автора и его публикацию, а значит, публикация не отразится в индексах. Опечатки в списках литературы могут привести к появлению отдельных объектов, существующих только в базах данных. В то же время ссылка на действительную публикацию в системе будет отсутствовать, и автор, знающий, кто на него ссылался, обнаружит

отсутствие и ссылки, и показателей цитируемости своих работ [6].

Это своеобразный (неумышленный) обман пользователей информационных систем авторами или издателями. Однако обман может быть и умышленным: так, многие работы в системе РИНЦ из-за различий в библиографических описаниях в списки публикаций попадают по два-три раза [1], завышая таким образом количество статей у отдельных авторов. Исключить или уменьшить долю таких ошибок с точки зрения информационной системы достаточно сложно, поскольку для этого нужно знать, где и как может ошибиться человек.

Второй тип ошибок – это ошибки, возникающие при транслитерации иноязычных фамилий. Здесь можно привести множество примеров. Так, фамилию Дударёнок Анны Сергеевны (научный сотрудник Института оптики атмосферы им. акад. В. Е. Зуева СО РАН) пишут и как Dudaryonok, и Dudarenok. Другой пример – Обьедков Сергей Александрович (канд. техн. наук, доцент Высшей школы экономики) в РИНЦ имеет «0 статей», потому что его фамилию пишут как Obiedkov, Ob'edkov, Obedkov. Однако именно этому автору вручена премия *Scopus Award Russia 2013* по результатам публикационной активности и цитируемости в мире. Как следствие – в КРН вообще нет профиля Сергея Александровича на русском языке, а есть несколько разных профилей на различные варианты написания фамилии, конечно, с потерянными ссылками цитирований.

Третий тип ошибок – это ошибки, возникающие при машинной обработке данных (этапы 3а, 4b, 5). Здесь объединены ошибки, допущенные в ходе распознавания сканированных документов компьютерными программами, и ошибки автоматизированного приведения данных в заданный формат (выборка необходимых данных из массива по формальным критериям). Таких ошибок можно было бы избежать при ручной проверке данных, однако на обрабатываемых наукометрическими системами массивах информации это невозможно из-за объёма данных. Например, РИНЦ официально сообщает, что бюджет проекта не позволяет проводить весь цикл обработки поступающей информации операторами в ручном режиме. Поэтому такие операции, как разбор ссылок или привязка публикаций и ссылок к авторам, организациям и журналам производится в РИНЦ в автоматическом режиме. Естественно, что далеко не все записи удаётся точно разобрать, особенно учитывая низкую культуру оформления списков цитируемой литературы в большинстве российских журналов [2].

К четвёртому типу ошибок можно отнести потери данных, возникающие при их передаче как по Интернету, так и в саму систему наукометрических индексов (этапы 4а, б).

Пятый тип ошибок – это ошибки в коде системы, которые искажают результативные данные: количество цитирований, индекс Хирша (этап 7). Такие ошибки также можно свести к минимуму благодаря точности и внимательности разработчиков и тестировщиков системы.



Рис. 2. Этапы передачи данных в систему цитирования с возможными ошибками

Схема этапов передачи данных с возможными ошибками на каждом этапе представлена на рис. 2.

Таким образом, можно сделать вывод о неизбежности определённой погрешности при составлении наукометрических показателей.

В ходе работы с наукометрической системой КРН мы получаем запросы пользователей на исправление ошибок в данных и показателях, однако мы можем выполнить около 70–80% заявок, поскольку ошибки были допущены во внешних по отношению к КРН данных. По условиям лицензионного соглашения, мы не имеем права такие данные редактировать.

С аналогичными проблемами сталкивается и система *Web of Science*: в процессе работы мы обращаемся к ней с заявками на исправление данных и в 15% случаев получаем отказ, связанный с невозможностью отредактировать внешние для системы данные. Один из последних примеров – публикация Фатеева Дениса Васильевича (канд. физ.-мат. наук, ст. науч. сотр. Саратовского филиала Института радиотехники и электроники им. В. А. Котельникова РАН) из материалов международной конференции [8], рецензируемых *WoS*. Часть авторов публикации в системе *WoS* указана без аффилиации с организациями. В ответ на нашу заявку мы получили уведомление о том, что данный издатель передаёт в систему *WoS* только аффилиацию первого автора, вследствие чего сотрудники *WoS* не могут проверить и дополнить аффилиацию Фатеева Дениса Васильевича. В результате КРН также не получает эту аффилиацию и не вносит статью в список публикаций Дениса Васильевича и Института радиотехники и электроники им. В. А. Котельникова РАН.

Важно подчеркнуть: часть ошибок смогут нивелировать авторы публикаций – целесообразнее потратить время и силы на дополнительную проверку статьи перед публикацией, чем на обращения к держателям различных наукометрических систем, которые далеко не всегда смогут помочь. Важнейшими пунктами проверки должны быть данные об авторе, заголовок публикации и список использованной литературы.

## Список источников

1. **Кузнецов А. В.** Для начала надо навести порядок в существующей системе РИНЦ / А. В. Кузнецов // Вестн. Рос. акад. наук. – 2014. – Том 84. – № 3. – С. 268, 269.
2. **РИНЦ** и Science Index в вопросах и ответах [Электронный ресурс] / Научная электронная библиотека. – Режим доступа:  
[http://elibrary.ru/projects/science\\_index/science\\_index\\_questions.asp](http://elibrary.ru/projects/science_index/science_index_questions.asp) (24.04.2014).
3. **Шерих Д. Ю.** «А» упало, «Б» пропало... Занимательная история опечаток. – Москва : Центрполиграф : «МиМ-Дельта», 2004. – 173 с.
4. **Garcia-Berthou E.** Incongruence between test statistics and P values in medical papers [Электронный ресурс] / E. Garcia-Berthou, C. Alcaraz // BMC Medical Research Methodology. – 2004. – Том 4. – № 13. – Режим доступа: <http://www.biomedcentral.com/1471-2288/4/13> (24.04.2014).
5. **Цыплухин В.** Опечатка ценой 0,5 млн евро [Электронный ресурс] / E-xecutive.ru. – Режим доступа: [http://www.e-xecutive.ru/knowledge/announcement/1182205/index.php?PAGE\\_NAME=read&FID=12&TID=8177](http://www.e-xecutive.ru/knowledge/announcement/1182205/index.php?PAGE_NAME=read&FID=12&TID=8177) (24.04.2014).
6. **Аникеева О. С.** Использование индекса научного цитирования в качестве характеристики научно-исследовательской деятельности учёных // Наука. Инновации. Технологии. – 2009. – № 6. – С. 5–11.
7. **Султанов В. Г.** FPIC3D – параллельный код для моделирования высокоэнергетических процессов в конденсированных средах / Султанов В. Г., Григорьев Д. А., Ким В. В., Ломоносов И. В., Матвейчев А. В., Острик А. В., Шутов А. В. // Вычислит. методы и программирование: новые вычислит. технологии. – 2009. – Том 10. – № 1. – С. 101–109.
8. **Maremyanin K. V.** Resonance detection of terahertz radiation in nanometer field-effect transistors with two-dimensional electron gas / Maremyanin K. V., Gavrilenko V. I., Morozov S. V., Ermolaev D. M., Zemlyakov V. E., Shapoval S. Y., Fateev D. V., Popov V. V., Maleev N. A., Teppe F., Knap W. // 35th Intern. Conf. on Infrared, Millimeter and Terahertz Waves (Rome, Italy, Sep 05-10, 2010). – New York : IEEE, 2010. – P. 1, 2.