

categories in the choice of the description's subject, i.e. important socio-psychological qualities for a given age group; and interpersonal connections, i.e. unidirectional and bi-directional (reciprocal) connections which help to identify the leader and outsider positions in the class.

*Key words:* linguistic portrait, semantic field, categorization, interpersonal relations.

УДК 81'35

## **ЗНАЧИМАЯ ЛЕКСИКА ОФИЦИАЛЬНОГО ДОКУМЕНТА НА ФОНЕ ДВУХ РЕФЕРЕНТНЫХ КОРПУСОВ<sup>1</sup>**

*Блинова О. В.*

Санкт-Петербургский государственный университет, 199034, Россия,  
г. Санкт-Петербург, Университетская наб., 7/9, o.blinova@spbu.ru

Статья направлена на сравнение списков значимой лексики (resp. списков ключевых слов), полученных с использованием двух разных по содержанию референтных корпусов одинакового объёма (по 1 млн. слов). Целевой корпус – это лемматизированная субколлекция текстов русских локальных документов типа «Информированное добровольное согласие на медицинское вмешательство» (38,5 тыс. слов). Референтными корпусами являются офлайновый версии НКРЯ и ГИКРЯ со снятой грамматической омонимией. Исследование показало, что «верхушки» двух списков «положительных» ключевых слов очень схожи, а сами ключевые слова отражают прежде «о-чёмность» («aboutness») текстов.

*Ключевые слова:* официальные документы, корпус русских локальных документов CorRIDA, значимая лексика, ключевые слова, референтный корпус.

1. В статье апробируется одна из методик выявления значимой лексики, которая в дальнейшем может применяться при анализе текстовых коллекций документов, вошедших в корпус CorRIDA (Corpus of Russian Internal Documents and Acts, Корпус русских локальных документов и актов).

Корпус CorRIDA формируется в рамках исследования, посвящённого функционированию официальных документов в социальных доменах здравоохранения, культуры и образования. В корпус включены так называемые «локальные документы» (Internal Documents) конкретных государственных учреждений, находящиеся в открытом доступе на сайтах поликлиник, школ, университетов, библиотек и др. Это тексты, с которыми мы как «простые» носители языка часто сталкиваемся в повседневной жизни. Конечной

---

<sup>1</sup> Исследование выполнено в рамках НИР по анализу соблюдения норм современного русского литературного языка при его использовании в качестве государственного в деятельности организаций культуры, здравоохранения и образования, включённой в план мероприятий НИИ Проблем государственного языка СПбГУ во исполнение комплекса мер, направленных на совершенствование государственной политики в области развития, защиты и поддержки русского языка на 2016-2020 гг. Совета по русскому языку при Правительстве РФ.

© Блинова О.В., 2018

целью исследования является оценка языка документов с точки зрения доступности для восприятия и понимания.

В настоящей статье анализируется одна коллекция из полуторамиллионного корпуса CorRIDA, это коллекция «информированных согласий», которые функционируют в домене здравоохранения («Информированное добровольное согласие на медицинское вмешательство» и др.). В коллекцию входит 100 текстов информированных согласий объёмом 50,6 тыс. токенов, 38,5 тыс. слов<sup>2</sup>.

2. Списки значимой лексики (или, иначе, списки ключевых слов, keywords) выявляются путём сравнения частот слов в двух корпусах. Первый корпус называется «целевым», или «объектным» (target corpus, далее – ЦК); его лексическая специфика выявляется «на фоне» второго, «референтного», корпуса (reference corpus, далее – РК). В результате получается список собственно ключевых слов, positive keywords, которые встречаются в ЦК значимо чаще, чем можно было бы ожидать, если судить по РК, а также список «негативных» ключевых слов, negative keywords, чьи частоты значимо низки в сравнении с РК. Метод выделения ключевых слов позволяет выявить лексическую специфику ЦК по сравнению с РК.

РК обычно более «общий» и «сбалансированный», а целевой – более «специализированный» [1]. Кроме того, считается, что РК должен быть (существенно) больше целевого. Например, в работе [2] указывается, что если РК больше ЦК менее, чем в пять раз, то использовать его рискованно. Между тем Э. МакЭнери и Р. Сяо [3], сравнивая два РК: 100-миллионный BNC и 1-миллионный Freiburg-LOB Corpus, получили практически идентичные списки ключевых слов, после чего заключили, что размер референтного корпуса не так уж и значим. М. Скотт также считает, что состав РК важнее размера (и при использовании разных жанрово-специфичных РК получаются существенно различающиеся списки ключевых слов) [4].

3. Рассмотрение ключевых слов широко используется для целей дискурсивного анализа, контент-анализа, изучения стилей и др. (обзор см., например, в работе [5]). Анализ ключевых слов, в частности, позволяет идентифицировать существенные особенности текстов, связанные с их жанровой спецификой [3, с. 68].

Существуют инструменты автоматического извлечения ключевых слов: WordSmith Tools, AntConc, WMatrix [5, с. 95]. В настоящем исследовании для этой цели используется программный пакет AntConc [6]. При подсчёте коэффициента keyness value в качестве метрики используется критерий отношения правдоподобия.

---

<sup>2</sup> Из списка слов, подлежащего анализу, исключены цифровые и некоторые алфавитно-цифровые комплексы, пунктуационные символы, в том числе числовые и буквенные обозначения пунктов документа.

**Таблица 1. Списки «положительных» ключевых слов, полученных с помощью двух РК**

НКРЯ как РК				ГИКРЯ как РК			
№	Абс. частота	Keyness	Ключевое слово	№	Абс. частота	Keyness	Ключевое слово
1	855	5092.517	медицинский	1	855	5200.907	медицинский
2	442	2626.464	лечение	2	442	2489.885	лечение
3	360	2146.122	согласие	3	360	2204.359	согласие
4	402	2064.088	врач	4	402	1959.546	врач
5	258	1658.182	информировать	5	258	1659.369	информировать
6	242	1491.317	подпись	6	240	1477.739	вмешательство
7	240	1438.399	вмешательство	7	242	1382.529	подпись
8	241	1265.169	здоровье	8	204	1379.029	они
9	240	1264.638	проведение	9	188	1270.870	давать
10	287	1252.489	г	10	196	1258.003	ф

Задачей является извлечение списков ключевых слов с использованием двух разных РК и сравнение таких списков. В качестве РК взяты офлайновая версия подкорпуса Национального корпуса русского языка (НКРЯ, [ruscorpora.ru](http://ruscorpora.ru)) со снятой грамматической омонимией и офлайновая версия подкорпуса Генерального интернет-корпуса русского языка (ГИКРЯ, [webcorpora.ru](http://webcorpora.ru)) со снятой грамматической омонимией<sup>3</sup>. Решено использовать два РК равного объёма (по 1 млн. слов). Подкорпус НКРЯ включает тексты электронной коммуникации, художественную и учебно-научную прозу, газетную публицистику, материалы устной речи (1 млн 61 тыс. слов). Подкорпус ГИКРЯ – это тексты интернет-коммуникации «ВКонтакте» и «ЖЖ», взято 1 млн. 92 тыс. слов<sup>4</sup>. ЦК, состоящий из текстов официальных документов («информированных согласий») существенно (в 25 раз) меньше референтного (38,5 тыс. слов).

Перед формированием списков ключевых слов словник ЦК был лемматизирован с помощью MyStem [7]. Кроме того, для унификации списков лемм были выполнены некоторые дополнительные преобразования, в частности, в составе списка лемм ГИКРЯ все объединённые нижним подчеркиванием неоднословные лексические единицы типа *в течение* были разбиты на части.

<sup>3</sup> Пользуясь случаем, хочу ещё раз поблагодарить коллективы НКРЯ и ГИКРЯ за предоставление доступа к онлайн-корпусам.

<sup>4</sup> В состав РК вошли в основном тексты ЖЖ («Живого журнала»).

**Таблица 2. Списки «отрицательных» ключевых слов, полученных с помощью двух РК**

НКРЯ как РК				ГИКРЯ как РК			
№	Абс. частота	Keyness	Ключевое слово	№	абс. частота	Keyness	Ключевое слово
1	2	0.000	неизвестный	1	1	0.000	методика
2	3	0.000	январь	2	1	0.000	нормативный
3	6	0.000	участие	3	1	0.000	полоса
4	1	0.001	механический	4	1	0.000	частый
5	1	0.001	речевой	5	2	0.000	кв
6	1	0.001	слабость	6	2	0.001	праздничный
7	1	0.001	транспортный	7	6	0.002	свободный
8	3	0.001	корень	8	2	0.003	влиять
9	10	0.001	правый	9	1	0.003	запрос
10	28	0.001	проблема	10	6	0.003	способный

В работе [3] учёные, получив лексические списки с помощью двух РК, сравнивали 10 «позитивных» ключевых слов («top ten positive keywords») и 10 «негативных» ключевых слов («top ten negative keywords»). Основания подобного сравнения для наших данных представлены в табл. 1 и 2 ниже (списки отсортированы по убыванию коэффициента «keyness» в табл. 1 и по возрастанию этого коэффициента в табл. 2).

Первые пять позиций совпадают и по составу ключевых слов, и по месту этих слов в списке (это *медицинский, лечение, согласие, врач, информировать*). Вторые пять позиций содержат два совпадения с разным порядком следования (*подпись* и *вмешательство*). Стоит прокомментировать наличие на 10-й позиции начальной буквы слова *ф* (из акронима *Ф. И. О.*) и начальной буквы слова *г*. (это сокращение слова *год*). Таким образом, в текстах документов по сравнению с референтными корпусами значимо часто встречаются сокращения.

Можно сделать некоторые предварительные выводы: во-первых, списки «положительных» ключевых слов, полученные с помощью разных РК, существенно схожи (совпадают 7 позиций из 10, первые 5 позиций совершенно идентичны); во-вторых, списки «негативных» ключевых слов не содержат совпадений.

Отмечено, что ключевые слова – это чаще всего: 1) имена собственные; 2) слова, которые и люди (а не только компьютерные программы) посчитали бы ключевыми, такие единицы являются хорошими показателями

тематики текста; 3. слова, которые являются индикаторами стилевых характеристик текстов, а не их тематики [8]. В полученных списках «положительных» ключевых слов преобладают единицы второй категории, говорящие, «о чём текст».

### **Библиографический список**

1. *Gries S.T.* Quantitative designs and statistical techniques // The Cambridge handbook of English corpus linguistics / ed. by D. Biber and R. Reppen. Cambridge University Press. 2015. P. 50-71.
2. *Berber-Sardinha T.* Comparing corpora with WordSmith Tools: How large must the reference corpus be? // Proceedings of the Workshop on Comparing Corpora. 2000. Vol.9. P. 7-13.
3. *Xiao R., McEnery T.* Two approaches to genre analysis: Three genres in modern American English // Journal of English Linguistics. 2005. Vol. 33. P. 62–82.
4. *Scott M.* In search of a bad reference corpus // What's in a word-list? Investigating word frequency and keyword extraction / ed. by D. Archer. Farnham, Surrey: Ashgate. 2009. P. 79-91.
5. *Culpeper J., Demmen J.* Keywords // The Cambridge handbook of English corpus linguistics / ed. by D. Biber and R. Reppen. Cambridge University Press. 2015. P. 90-105.
6. *Anthony L.* AntConc (Version 3.5.6). Tokyo, Japan: Waseda University. URL: <http://www.laurenceanthony.net/software> (дата обращения: 01.04.2018).
7. Морфологический анализатор Mystem 3.1 URL: <https://tech.yandex.ru/mystem/> (дата обращения: 01.04.2018).
8. Definition of key-ness. Wordsmith Tools online manual. URL: <http://www.lexically.net/wordsmith/index.html> (дата обращения: 01.04.2018).

### **OFFICIAL DOCUMENTS' KEYWORDS LISTS MADE ON THE BASE OF TWO REFERENCE CORPORA: A COMPARISON**

*Blinova O. V.*

St. Petersburg State University, 7/9, Universitetskaya emb., St. Petersburg,  
199034, Russia, o.blinova@spbu.ru

The article is aimed at comparing the lists of keywords, obtained using two different reference corpora of the same size (1 million words). The target corpus is a lemmatized collection of texts of internal documents such as «The informed voluntary consent to medical intervention» (38,5 thousand words). The reference corpora are the off-line disambiguated subcorpus of the RNC ([ruscorpora.ru](http://ruscorpora.ru)) and the off-line disambiguated subcorpus of the GICR ([webcorpora.ru](http://webcorpora.ru)). The study showed that the «tops» of two lists of positive keywords are very similar, and the keywords themselves indicate primarily «aboutness» of the texts.

*Key words:* official texts, Corpus of Russian Internal Documents and Acts «Cor-RIDA», keywords, reference corpus.