КроссЛексика: Готовая версия

Большаков Игорь Алексеевич
Независимый исследователь, Москва
iabolshakov@gmail.com

Гельбух Александр Феликсович
Профессор национального политехнического института, Мехико
gelbukh@gelbukh.com

Общая характеристика (1/3)

- **КроссЛексика – самое большое в мире собрание всех типов связей между русскими словами.** Сугубо компьютерных словарей, сопоставимых с КЛ по структуре, размеру словника и количеству связей между элементами словника, не существует ни для одного иного языка в мире, даже английского.
- КЛ предназначена для самого **широкого круга пользователей**, включая ученых (в том числе – лингвистов), преподавателей, инженеров, журналистов, бизнесменов, дипломатов, военных, учащихся, студентов, аспирантов, пенсионеров, домохозяек.
- Лингвистическая база КроссЛексики основана на десятках словарей, сотнях других печатных источников и многих тысячах запросов к интернет-поисковикам Гугл и Яндекс.

Общая характеристика (2/3)

- КЛ поддерживается в **двух основных версиях**:
  - Сокращенная по объему словника и количеству связей интернет-версия с ограниченным пользовательским интерфейсом, дающая доступ с компьютера под любой операционной системой.
  - Интерактивная полнообъемная версия, автономно воплощаемая на компьютерах под ОС Windows, с полным набором современных интерактивных средств.
- **Обе версии КЛ позволяют**:
  - обучаться русскому языку во всех сферах его использования и с полным учетом лексики, морфологии и синтаксиса,
  - совершенствовать русские тексты (документы, статьи, брошюры, книги) в процессе их создания за компьютером.

Общая характеристика (3/3)

Полная интерактивная версия:

- Содержит в несколько раз больше слов и межсловных связей и позволяет создавать разнообразные производные словари, как чисто лингвистические (синонимов, паронимов, моделей управления и др.), так и тематические (по кулинарии, медицине, обработке документации и др.)
- Поддерживает английский интерфейс, содержа двусторонний англо-русский словарь для ввода запросов по-английски и нахождения переводов русских слов и оборотов.
- Обеспечивает удобный доступ к мировому информационному фонду через три важных поисковика.

На июнь 2016 г. предлагается в свободном доступе **сокращенная интернет-версия** КроссЛексики: http://www.xl.gelbukh.com

Сопоставительные ресурсы для русского языка

- **в печатной форме:**
  - **Тихонов** А.Н., Тихонова Е.Н., Тихонов С. А., Чупашева О. М., Зуева М. Ю. Комплексный словарь русского языка. Москва, 2007.
  - **Морковкин** В. В., Богачева Г. Ф., Луцкая Н. М. Большой универсальный словарь русского языка. Москва, 2016.
- **в интернете:**
  - Словарь ассоциаций Reright: *reright.ru*
  - Национальный корпус русского языка: *ruscorpora.ru*

Сопоставительные ресурсы для других языков

Для английского языка

в печатной и электронной форме:

- Oxford Collocation dictionary for students of English
  - Oxford University Press, 2009
  - Online Oxford Collocation dictionary
- Macmillan Collocations Dictionary for Learners of English
  - Macmillan Publishers Ltd, 2016
  - *www.macmillandictionary.com*

Для испанского языка

DiCE: Diccionario de Colocaciones del Español

www.dicesp.com/paginas

Для французского языка

González Rodrígez, Toni. Dictionnaire des collocations

www.tonitraduction.net

КроссЛексика – единственный сугубо компьютерный словарь

- Если объект ИС состоит из нескольких частей, то он должен быть доступен через любую его часть в одинаковом виде. Так, коллокация *наблюдать за ссорой* должна быть найдена по обоим коллокатам: *наблюдать* и *ссора*.
- Если объект ИС имеет варианты с разными связями, то эти варианты должны быть размечены (пронумерованы) по всей БД . У объектов-респондентов должно быть указано, какой конкретно вариант имеется в виду. Так, если в словаре не разметить омонимы, то будут признаны правильными коллокации типа *симпатичное доверенное лицо*.
- Коррекция объекта в ИС должна производиться синхронно, где бы этот объект в БД ни находился. Выполнить это требование трудно, если просто оцифровать печатный словарь страница за страницей.
- Компьютерный словарь должен предоставлять свои ресурсы в реальном времени как человеку-пользователю, так и программам, связанным с этим словарем.

Глобальная структура КроссЛексики: Гигантская матрица {Словник x Словник}

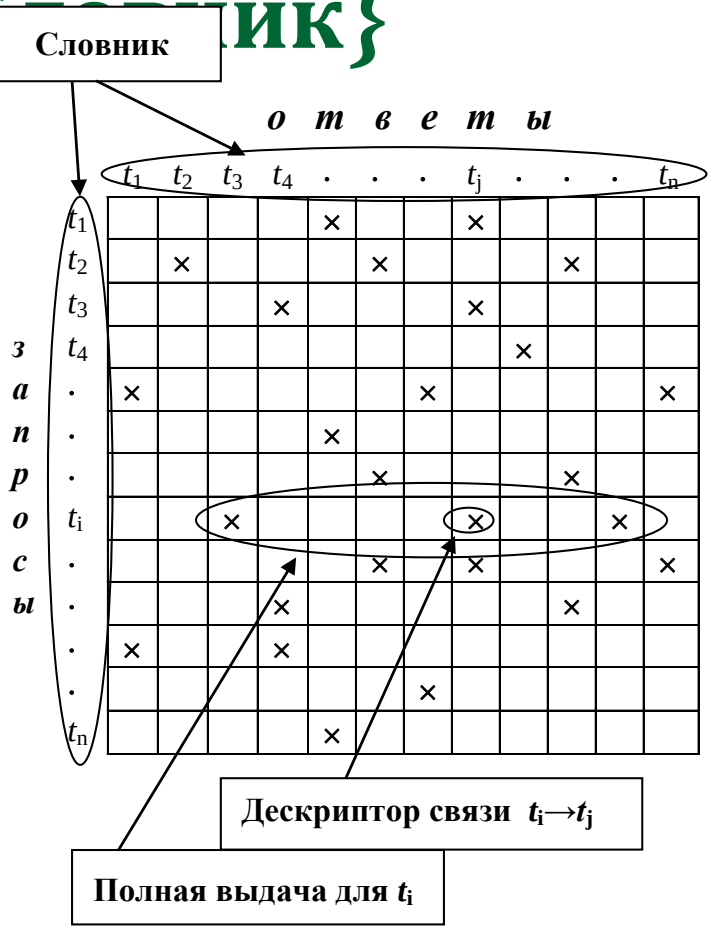

- Элемент словника = вокабула
- Элементы матрицы – дескрипторы связи между запрошенной t_i и ответной вокабулой t_j
  i, j = 1, ..., 310000+
- Связи ограничены языком и реалиями внешнего мира.
  Из 100 миллиардов ячеек матрицы непуста лишь каждая 10000-я.
- У вокабулы в среднем 32 связи.

Вокабулы относятся к четырем частям речи

- ***Субстантивные***:
  - Отдельное существительное (42%): *абажур, битва, бифштекс, благо, блины...*
  - Именное словосочетание: *алкогольные напитки, ближнее зарубежье, сельское хозяйство, точка зрения, уровень жизни, экономический рост...*
- ***Глагольные*** в инфинитиве или личных формах:
  - Одиночный глагол (54%): *говорить, идти, обсуждать, спать, ругать...*
  - Глагольный оборот: *навести страх, оказывать внимание, испытать ужас…*
- ***Адъективные*:**
  - Отдельное прилагательное: *абстрактный, авансовый, автономный, авантюрный...*
  - Отдельное причастие: *задвинутый, мытый, перевезенный, желающий...*
  - Согласованный адъективный оборот: *бросающийся в глаза, хорошо одетый...*
  - Несогласованный адъективный оборот: *бойцовской породы, большой дальности, в елочку...*
  - Наречие или ограничительная частица в синтаксической роли определения существительного: *только, исключительно, фактически*...
- ***Адвербиальные*:**
  - Отдельное наречие: *абсолютно, абстрактно, адски, аляповато, быстро...*
  - Отдельное деепричастие: *базируясь, надев, торопясь, шепча...*
  - Адвербиальный оборот: *аккуратным образом, более или менее, как выжатый лимон, в особой степени, куда попало, мелкой дрожью...*

Первая цель КроссЛексики (1/2)
- покрытие максимально широкой аудитории

- ***Политематичность***, т.е. как можно более полное покрытие областей использования языка: экономики, финансов и бизнеса; социальной и политической сферы; гуманитарных наук и религии; точных и естественных наук; инженерии и технологий; строительства и архитектуры; медицины; экологии; спорта; кулинарии; бытового языка включая бранную лексику.
- ***Концентрация информации*** из академических и специальных словарей, из потока новостей, политической, экономической и научной аналитики в интернете, из объявлений, гламурных журналов по знаменитостям, моде, туризму, автомобилям.
- Включение как ***лингвистической***, так и ***энциклопедической*** информации.

Первая цель КроссЛексики (2/2)
- покрытие максимально широкой аудитории

- Упрощенная, но ***наглядная система помет*** при словах и коллокациях. Например, особенности ***стиля*** размечаются как *нейтральное*, *специальное/книжное, разговорное, вульгарное* и *неграмотное*. Тем самым КЛ затрагивается как бытующая, так и нормативная стороны языка. КЛ предостерегает пользователя от «некультурных» выражений типа *более лучше* или *болтнуть глупость*.
- ***Толерантный интерфейс***:
  - Включение графических опций новых слов, например, *бренд* и *брэнд, плеер* и *плейер.*
  - Необязательность знания чисто лингвистических понятий и терминов. Например, для секции выдачи можно пользоваться названием *Одноклассники* вместо *Когипонимы*.
- ***Упрощенческие отклонения от лингвистического канона***. Например, два разных вида глагола и два числа существительного рассматриваются как разные слова; причастия и деепричастия отделены от глагола и отнесены к прилагательным и наречиям соответственно.

Вторая цель КроссЛексики
– встраивание пользователя в современный информационный мир

- Предоставление ***английского интерфейса***, что учитывает современную лингвистическую ситуацию. Встроенный ***двусторонний англо-русский словарь*** позволяет автоматически переводить запросы с английского языка, получать переводы русских слов и коллокаций на английский и многих английских коллокаций на русский.
- Конструирование запросов к ***трем важнейшим поисковикам*** интернета путем выбора из словника или имеющегося набора коллокаций – для получения более подробной информации по выбранному слову, обороту или проблеме.

Принципы построения КроссЛексики (1+2+3/5)

- ***Включение трех известных типов связей*** между вокабулами:
  - ***Семантико-синтагматических*** (далее синтаксических)
  - ***Семантико-парадигматических*** (далее семантических)
  - ***Паронимических*** (т.е. буквенного или морфного сходства).
- ***Покрытие всех типов синтаксических связей*** между четырьмя главными частями речи – существительными, глаголами, прилагательными и наречиями. Все типы связей рассматриваются в обе стороны, так что в выдаче предусмотрены 22 разноименных секции, никогда не покрываемые полностью.
- ***Сетевой принцип***: вокабула включается в словарь вместе со всеми обнаруженными на текущий момент ее связями. (Иные словари предпочитают линейный принцип: простую последовательность статей словника.)

Принципы построения КроссЛексики (4+5/5)

- ***Декомпозиционный принцип***: любое полнозначное слово или словосочетание, входящее в многословную вокабулу, само является отдельной вокабулой, и можно проследить путь декомпозиии, например,

  авиа- и железнодорожный транспорт =
  авиационный транспорт + железнодорожный транспорт
  авиационный транспорт = авиационный + транспорт
  железнодорожный транспорт = железнодорожный + транспорт

- ***Языковая многоуровневость***: кроме указанных связей синтаксического и семантического характера для каждой вокабулы дается ее ***морфологическая парадигма.*** Существительные склоняются по шести стандартным и двум дополнительным падежам; глаголы представлены инфинитивом и 12 личными формами; для прилагательных учитываются все значения рода, числа, падежа и одушевленности.

Коллокации (= словосочетания)

- **Коллокация – это совокупность двух полнозначных вокабул, синтаксически связанных в тексте и устойчиво совместимых по смыслу.**
- **Коллокации бывают частотными и редкими, свободными и фразеологическими, включают разнообразные предикативные выражения.**
- В синтаксической связи между двумя полнозначными вокабулами может стоять **служебное слово**, предлог или сочинительный союз *и / или / да*:

  полнозн. слово1 →(***служебное слово***)→ ***полнозн. слово2***

  сотрудничество → ради → мира

- Каждая коллокация доступна **с двух сторон**.

Типы многочисленных коллокаций (сотни тысяч) (1/2)

- Определительная пара **существительное – прилагательное**:
  краснокочанная капуста, явный наглец, полная ясность…
- **Глагол –** его прямое / косвенное / предложное **дополнение-существительное**
  (включая ходовые обстоятельства):
  рассмотреть вопрос, *ковырять в носу, остаться из-за погоды, купить на рынке, отличаться сдержанностью...*
- **Причастие / прилагательное –** его прямое / косвенное / предложное **дополнение-существительное**
  (включая ходовые обстоятельства):
  рассмотревший вопрос, *ковырявший в носу, оставшийся из-за погоды, красный от гнева, купленный на рынке, отличающийся нравом,...*
- Определительная пара **глагол / прилагательное / наречие – наречие**:
  резко высказаться, полностью ясный, ужасно страшно...

Типы многочисленных коллокаций (сотни тысяч) (2/2)

- **Подлежащее-существительное – сказуемое в виде личной формы глагола или краткого адъектива**:
  самолет вылетел, внимание (было / будет) привлечено, доклад (был / будет) краток, враг напал, глазки бегают, категоричность смущает, детсад закрылся …
- **Существительное –** подчиненное ему **существительное**:
  сердце матери, наложение взыскания, отличия в произношении, борьба против терроризма…
- **Деепричастие / наречие –** его прямое / косвенное / предложное **дополнение-существительное**:
  рассмотрев вопрос, ковыряя в носу, оставшись из-за погоды, купив на рынке, отличаясь сдержанностью, близко от города,...

Некоторые типы малочисленных словосочетаний (единицы или десятки тысяч)

- **Устойчивые сочиненные пары**:
  автобусы и троллейбусы, ясный и четкий, экономический и культурный, быть или не быть, взвесить и решить, власть и бизнес, в срок и в полном объеме, базы и склады, наука и техника, авиа- и железнодорожный транспорт, десять заповедей и семь смертных грехов...
- **Глагол** – его **инфинитивное дополнение**:
  собраться поехать, мечтать выкупаться, хотеть перекусить...
- **Существительное** – его **инфинитивное дополнение**:
  соблазн сказать, желание уйти, проблема выжить...
- **Прилагательное / причастие** – его **инфинитивное дополнение**:
  готовый действовать, желающий начать, агитирующий голосовать...
- **Наречие / деепричастие** – его **инфинитивное дополнение**:
  абсурдно полагать, безумно ввязываться, берясь изучать, боясь возразить, бессмысленно идти...

Семантические связи

Самые многочисленные:

- **Синонимы**
- **Семантические дериваты**
  Простой пример группы СД:
  { *извлечение; извлекать, извлечь; извлеченный, извлекающий, извлекший; извлекая, по извлечении, путем извлечения* }

↑ **Здесь встречаются элементы канонических морфопарадигм** ↑
↑ **и дается основное множество энциклопедических сведений** ↑

Менее многочисленные:

- **Когипонимы.** Пример**:** *мясо → вырезка, грудинка, гуляш, котлеты, фарш…*
- **Ассоциации.** Пример**:** *аденоиды → аллергия, бассейн, гланды, гомеопатия, кашель, лазеротерапия, миндалины, слух…*
- **Меронимы / холонимы**
- **Гипонимы / гиперонимы**
- **Антонимы**

Все указанные связи хорошо известны, кроме ассоциаций. Они извлекаются из сочиненных пар в запросах к Рунету и в БД поисковиков.

Вокабулы с наибольшим числом ассоциаций в Рунете

558	*беременность*	125	*человек*
264	*здоровье*	122	*любовь*
257	*алкоголь*	121	*бизнес*
172	*спорт*	121	*курение*
143	*диабет*	120	*дети*
136	*диета*	117	*культура*[1]
131	*цены*	112	*похудение*
127	*мужчины*	104	*религия*

Использование семантических связей

- СемСы помогают понять ***смысл*** вокабул.
  Примеры:
  Synonym (*граффити*) = *настенная живопись*
  Synonym (*графт*) = *трансплантат*
  Synonym (*халяльный*) =
  отвечающий мусульманским нормам
  Hyperonym (*эндометриоз*) =
  акушерско-гинекологическая болезнь
- СемСы помогают построить словосочетания, в КЛ отсутствующие. Пример:

(**Hyperonym**(*каллы*) = *цветы*) & (*букет цветов*)
⟶ (*букет калл*)

- СемСы отражают многочисленные **энциклопедические сведения**

Энциклопедические сведения

- Названия геообъектов: континентов, океанов, морей, горных цепей…
- Названия крупнейших городов мира в привязке к странам
- Сведения о 60 иностранных государствах (по 20 ведущим – более подробные)
- Названия и другие сведения о десятках городов и регионов России
- Около 300 наиболее частых русских имен вместе с их диминутивами
- Имена ряда известных политических, деловых, научных и культурных деятелей мира
- Названия ряда крупных организаций и корпораций мира
- Названия ряда известных художественных произведений мира
- Терминология точных, естественных и гуманитарных наук, спорта, кулинарии; медицинская терминология

Основное приложение – диалоговое

- ***Предпосылка***: Пассивное знание языка у многих заметно шире активно используемых языковых средств. Если показать, как можно выразить ту же мысль иначе, пользователь легко найдет более подходящий и идиоматичный вариант.
- ***Характер работы***: пользователь вводит запрос и использует выдачу
  - для углубленного изучения русских слов и выражений или
  - для редактирования создаваемого текста с целью придать ему правильную и идиоматичную форму

Примеры лингвистических справок

- Как можно выразиться глаголом о плате за *проезд?* – *оплатить / оплачивать проезд* либо *платить / заплатить за проезд* (*проплатить проезд* и *оплатить за проезд* тоже включены, но снабжены пометами разговорности ● и запрета ● соответственно)
- Как «запустить» *иск*? – Можно *внести / возбудить / вчинить / подать / предъявить иск,* а также *обратиться с иском.*
- Как еще можно назвать *бразильских женщин?* – *бразильянки.* *А* как *иракских женщин*? – Да никак иначе! (Но *иракец, иракцы* среди семантических дериватов есть)

Различение паронимов

- вероятный

ЯВЛЯЕТСЯ ОПРЕДЕЛЕНИЕМ ДЛЯ:

адрес
альтернатива
вариант
версия
визит
встреча
выбор
гипотеза
запасы
изменение
.....

- вероятностный

ЯВЛЯЕТСЯ ОПРЕДЕЛЕНИЕМ ДЛЯ:

автомат
алгоритм
анализ
анализатор
аспекты
вывод
задача
идеи
контроль
логика
.....

Одноименными зонами выдачи формируются лингвистические словари

- Морфологический словарь
- Словарь определительных словосочетаний
- Словарь глагольно-именных словосочетаний
- Словарь моделей управления для глаголов
- Словарь моделей управления для существительных
- Словарь синонимов
- Словарь морфемных паронимов
- Словарь буквенных паронимов
- Словарь смысловых ассоциаций
- Словарь семантических дериватов
- и другие

Пример: Словарь моделей управления для глаголов

- Содержит списки «валентностей» 14 тыс. глаголов, иллюстрированных 460 тыс. примеров.
- Количество беспредложных и предложных «валентностей» у глагола иногда непривычно:

  28 – *организовать*

  23 – *установить*

  13 – *изучать*

  12 – *проверять*

  11 – *соорудить*

  9 – *обеспечивать*

  6 – *анализировать*

Для любого специального подсловника можно «вырезать» тематический словарь

- ***КроссЛексика-чиновник*** – для широкого круга работников сферы управления.
- ***КроссЛексика-гурман*** – для любителей поесть или приготовить что-то самому.
- ***КроссЛексика-пациент*** – для широкого круга обычных людей, часто посещающих врачей.
- ***КроссЛексика-красотка*** – для девушек и дам, желающих видеть себя здоровыми и красивыми.

Недиалоговые приложения
(не входят в словарь)

Внешняя программа обращается к словарю через специальную утилиту КЛ и использует выдачу самостоятельно. Примеры:

- Автоматическое обнаружение и исправление смысловых ошибок типа *истерический центр* или *неутомимый голод* – с помощью коллокаций и паронимов КЛ.
- Разрешение неоднозначности омонимов по контексту – с помощью коллокаций КЛ.
- Лексическая фильтрация результатов синтаксического разбора – с помощью коллокаций КЛ.
- Стеганография и стеганализ – с помощью коллокаций и синонимов КЛ.

Глобальные параметры двух версий на май 2016

- **Вокабул** **310 тыс. (138 тыс.)**
  - Существительных 46%
  - Глаголов 13%
  - Прилагательных 24%
  - Наречий и др. ч. р. 16%
- **Связей между** **9.98 млн. (6.33 млн.)**
  - Синтаксических **5.68 млн. (4.28 млн.)**

    из них:

    определительных 29%

    глагольно-именных 24%
  - Семантических **3.32 млн. (1.72 млн.)**
  - Паронимических **0.97 млн. (0.33 млн.)**

Несколько сравнений (1/2)

- Большой универсальный словарь русского языка (В. В. Морковкин и др., 2016):
  - Около 450 тыс. русских словосочетаний
  - 30 тыс. словарных статей
- Oxford Collocation Dictionary for students of English (Oxford, 2009):
  - 250 тыс. английских словосочетаний
  - 9 тыс. словарных статей
- КроссЛексика, полная интерактивная версия (2016):
  - 2.84 млн. русских словосочетаний
  - 130 тыс. вокабул в словосочетаниях

Несколько сравнений (2/2)

СМ – словарь Морковкина СА – словарь ассоциаций Reright

Существительное	СМ	СА	КЛ
сравнение по числу связей			
беременность	0	193	1709
здоровье	152	0	1087
алкоголь	0	206	557
спорт	93	192	523
диета	0	210	419
аборт	0	196	148
сравнение по числу определений			
человек	653	71	1394
лицо1	164	64	978
женщина	28	64	888
глаза	59	64	842
политика	74	64	635
шутка	77	64	192

Вопросы направляйте по адресу
iabolshakov@gmail.com
и посмотрите сокращенную интернет-версию
http://www.xl.gelbukh.com