

Представление устойчивых лексических сочетаний в компьютерном тезауусе RussNet

Азарова И. В.
azic@bsr.spb.ru

Синопальникова А. А.
anna.sinopalnikova@gmail.com

Смрж П.
smrz@fit.vutbr.cz

В докладе обсуждаются вопросы уточнения структуры компьютерного тезаууса RussNet, ориентированного на «ядерную» структуру современной лексической системы русского языка. При построении wordnet-словарей выявляются частотности значений слов в современных текстах, и определяется набор контекстных маркеров, разграничивающих значения. Описывается методика анализа контекстных маркеров, позволяющая разграничивать свободные и устойчивые словосочетания.

Компьютерный тезауус RussNet

Компьютерный тезауус RussNet построен в соответствии с набором основополагающих принципов создания wordnet-словарей¹. Элементарной единицей тезаууса является набор синонимичных лексем (минимально – одна лексема) знаменательной части речи с определенным значением, так называемый «синсет». Некоторое слово может входить в несколько синсетов в зависимости от числа его значений. В случае лексических лагун допускается включение в синсет устойчивых словосочетаний (*время года, большой палец* и проч.). Элементарные объекты связаны между собой родовидовыми отношениями в набор семантических деревьев (например, *время, совокупность, еда, растения, животные, человек, двигаться, говорить, мыслить* и проч.) Узлы семантических деревьев связаны между собой различными семантическими отношениями, например: часть-целое, антонимия, каузация и проч. Помимо внутренних семантических отношений, имеются внешние, которые связывают элементы структуры национального тезаууса с выделенным набором понятий Межъязыкового лингвистического индекса (ILI).

В методологическом плане стандартная процедура построения wordnet-словарей включает следующие положения.

- (1) Словарь опирается на сбалансированный корпус современных текстов; для RussNet он включает тексты 1985-2004 годов общим объемом около 21 млн. словоупотреблений, основу (60%) которого составляют газетные и журнальные статьи на темы повседневной жизни, экономики, политики, науки, культуры и спорта в сочетании с фрагментами литературно-художественных текстов (15%), деловыми текстами и законами (10%), фрагментами научных трудов (15%).
- (2) Ядерная структура тезаууса задается примерно двумя тысячами наиболее частотных слов (существительных, глаголов, прилагательных, наречий), которые встречаются более 100 раз на миллион словоупотреблений² в корпусе современных текстов.
- (3) Разные значения некоторого слова, представленные в тезауусе, упорядочены в соответствии с частотностью их употребления в корпусе текстов.
- (4) В wordnet-словарях представлена, как правило, общая, нетерминологическая лексика, хотя расширения базовой структуры будут включать терминологические элементы, которые тесно связаны с определенными тематическими областями.

При разработке RussNet стандартная методика были расширена следующими положениями.

- (1) Элементы синонимического ряда различаются стилистической окраской и частотностью употребления в корпусе. При этом один из синонимов является доминантой синсета – наиболее частотным, нейтральным способом выражения лексического значения в данном языке; остальные элементы ряда значительно уступают доминанте в частотности и закреплены обычно за какой-либо функциональной сферой использования языка.
- (2) Основным инструментом при разграничении значений слова в RussNet является контекстный анализ. Анализируя структуру контекста слова в корпусе текстов, мы выделяем статистически значимые маркеры, в качестве

¹ Более подробно методика построения тезаууса описана в статьях (*Азарова и др.* 2003; *Azarova et al.* 2002) и на сайте Санкт-Петербургского университета: <http://www.phil.pu.ru/depts/12/RN/>

² Далее этот показатель обозначается ipm (items per million).

ве которых может выступать и определенная грамматическая форма, и принадлежность к некоторому семантическому дереву родовидовой иерархии RussNet, или оба этих показателя вместе. Эти признаки должны проявляться устойчиво: более чем в 33% контекстов для рассматриваемого значения в корпусе; контекстные маркеры задают рамку валентностей для некоторого значения слова.

(3) Значения слов, частотность появления которых в корпусе составляет менее 1% контекстов для слова, считаются окказиональными (неустойчивыми) и не включаются в тезаурусное описание.

Изучение функционирования слов в реальных текстах является необходимой (основной) составляющей процесса построения RussNet. На различных стадиях нашей работы мы используем контекстные данные для:

- **Установления доминанты** синонимического ряда (на основе частотных показателей). Например, доминантой синонимического ряда {еда, пища, продукт₃, харчи} является лексема еда, так как по сравнению с остальными членами синсета, она обладает наиболее высокой частотой встречаемости – 106,8 ipm (ср.: пища – 50,1 ipm, продукт₃ – 24,9 ipm, харчи – 6,8 ipm).
- **Различения значений слова** на основе контекстных маркеров. Например, различные грамматические и лексические маркеры сопровождают реализацию в тексте разных значений глагола мешать: мешать₁ мне работать => <кому? N3 {человек₁, лицо₃}> <Inf {делать₁}>; мешать₂ клей палочкой => <что? N4 {вещество₁, субстанция₁}> <чем? N5 {предмет₁, вещь₁}>.
- **Установления семантических отношений** между единицами (на основе типичных лексико-синтаксических конструкций). Например, конструкция X и другие Y обычно является показателем отношения гипонимии: После этого проведите через марлю и заправляйте им **винегрет, салат, сельдь и другие блюда**.

Рамки валентностей

Использование данных RussNet для решения прикладных задач, связанных с семантической обработкой текстов (Азарова, Иванов, Секликов 2004), показало, что необходимо включить в структуру RussNet не только результаты контекстного анализа, но и самих контекстных данных. Идея расширения лексикона за счет контекстной информации была сформулирована в нескольких работах по вариантам wordnet-представлений и общим словарям (Stranakova-Lopatkova, Zabokrtsky 2002; Agirre, Martinez 2002; Bentivogli, Pianta 2004.) Форма представления контекстной информации может варьироваться, однако чаще всего она представлена в виде **рамок валентностей**.

В RussNet мы различаем два типа валентностей: активную и пассивную. Для признаков слов (глаголов, прилагательных и их дериватов) задаются активные валентности, например: взять => <что? N4 {предмет₁, вещь₁}>; для зависимых слов (наречий и существительных) указываются пассивные валентности, например: <в лицо> {лицо₄}> <=> {сказать₁}.

Активная рамка валентностей некоторого признакового слова задает грамматические и семантические параметры его зависимых слов. Формат активной рамки валентностей состоит из перечня позиций, которые по данным анализа контекстов корпуса регулярно сопутствуют реализации данного значения у слова. Каждая позиция имеет характеристику обязательности/факультативности, обязательная позиция рамки реализуется чрезвычайно регулярно (более чем в 66% случаев), причем в тех случаях, когда в непосредственном контексте (данном предложении) этот элемент отсутствует, он задан для некоторого предшествующего слова, является подразумеваемым из более общего текстового контекста. Факультативная валентность реализуется не столь последовательно (более чем в 33% контекстов), но при разграничении значений данная позиция значима. Элементы контекстного окружения, появляющиеся с меньшей частотой³, считаются окказиональными (незначимыми).

Валентная позиция характеризуется семантически и грамматически. Одна из семантических характеристик задает функцию данного элемента ситуации. Традиционный способ различения валентностей на основе ролевой семантики не был принят из-за того, что ограниченный набор семантических ролей во многих случаях недостаточен для функциональной характеристики, кроме того, в случаях разграничения объекта и результата, пациента и адресата приписывание определенной метки носит не всегда объективный характер. Мы исходим из предположения, что **семантические функции валентностей** тесно связаны с семантическими деревьями RussNet. Например, для дерева двигаться помимо субъекта движения, важными функциями будут: начальная точка, от которой было начато движение, и конечная точка, к которой направлено движение. Естественно, что эти функции важны для глаголов из соответствующего дерева в разной степени, например, для глагола двигаться характерна только функция субъекта, а для глагола направиться – субъекта и конечной точки движения. Чем более конкретно значение признакового синсета, тем большее число валентностей возможно. Привязка семантических функций к определенному классу слов сближает наш подход с методикой, принятой в проекте FrameNet⁴. Однако, мы предполагаем, что нет необходимости фиксировать все семантические позиции (они могут уточняться) для дерева и вводить

³ Пороговые значения для разграничения обязательных, факультативных и окказиональных валентностей будут в дальнейшем уточняться. Возможно, необходимо ввести интервал значений, например: 25-35% и 65-75%. В настоящее время накапливаются данные о распределении значений в данных диапазонах.

⁴ Baker, Fillmore, Lowe 1998. См. также FrameNet homepage: <http://framenet.icsi.berkeley.edu/~framenet>

смысловые обозначения. Например, функция конечной точки движения для глагола *направиться* чаще всего реализуется при помощи указания объекта, к которому или внутрь которого происходит движение (*направиться в дом, к дому, в кусты* и т.д.). Однако, локализация может быть дополнена уточнением лица, по направлению к которому происходит движение (*направиться к нам, в комнату к отцу* и т.д.). В качестве функции будет выступать обобщенное название *объект*₂.

Грамматическая характеристика валентности в рамке указывает на **типовые способы** реализации некоторой валентной позиции. Например, в приведенном выше примере с *направиться* два синтаксических варианта будут включены в рамку: сочетание предлога *в* и винительного падежа имени и предлогом *к* в сочетании с дательным имени. Эти способы характеристики направления движения покрывают 71% контекстов употребления глагола, кроме того, встречаются и другие способы грамматической реализации этой позиции, но они встречаются окказионально (1-5% контекстов), и вряд ли возможно составить исчерпывающий перечень. Регулярные замены грамматических форм, например, изменение формы винительного падежа при переходных глаголах под отрицанием, не вносятся в рамки валентностей, потому что замена зависит от контекста употребления признакового слова (находится на уровне синтаксической реализации) и не выполняется обязательно, поэтому эта трансформационная операция выполняется на основании правил на уровне семантического блока отождествления типов.

Еще одна характеристика задает семантический тип слов, которые могут занимать соответствующую валентную позицию. **Семантическая квалификация валентностей** осуществляется посредством отсылок к **семантическим деревьям тезауруса RussNet**. Например, субъектная позиция глагола *направиться* отправляет к дереву "человек". В других случаях, семантическая квалификация может указывать на часть семантического дерева, например для прилагательного *большой* в значении 'обладающий высокой интенсивностью признака' (*большой друг, большой дурак, большой демократ*) семантической отсылкой будет часть дерева "человек", указывающая на именование человека через квалифицирующий признак, при этом другая часть этого дерева: именованья людей по возрасту (*дедушка, ребенок*), полу (*юноше, женщина*) и проч. не будут семантическими маркерами данного значения, ср. *большой дядя, большой юноша, большой мальчик*. Семантическая отсылка может указывать на конкретный синсет (синсеты) в RussNet структуре (например, для валентности глагола *кукарекать*). Семантические деревья RussNet определенным образом коррелируют с традиционным способом описания способов наполнения валентностей, например помете "одушевленные" соответствуют деревья с вершинами *человек* и *животные*, "предметы" – *естественный объект, артефакт, еда* и т.д. Наборы деревьев также используются для семантической квалификации.

Выделение устойчивых словосочетаний

В связи с автоматической обработкой большого количества текстовых данных особое значение приобретает вопрос о формальных признаках, позволяющих разграничивать свободные и устойчивые сочетания лексических единиц. На данный момент практическое решение этого вопроса остается одной из актуальнейших проблем современной компьютерной лингвистики (Sag et al. 2002; Calzolari et al. 2002.).

В wordnet-словарях нет единой схемы включения устойчивых словосочетаний. В принстонском WordNet (Fellbaum 1998; Fellbaum (ed.) 1998), наряду с фразеологическими единицами, в синсеты регулярно включаются свободные словосочетания, назначением которых является облегчение использования словаря человеком-пользователем. Такой подход применительно к русскому языку дал бы огромное число текстовых форм. В GermaNet⁵ вставлялись многословные определения для более четкой фасетной организации согипонимов, причем эти синсеты помечаются как искусственные единицы, чтобы они не смешивались с реальными языковыми формами выражения значения.

В RussNet проблема представления устойчивых словосочетаний решается с привлечением статистических методов обработки текстовых данных, поскольку традиционные лексикографические источники, так же как и ассоциативные словари, не предоставляют последовательной информации. Общая стратегия состоит в том, чтобы устойчивые словосочетания включались в синсеты, поскольку они эквивалентны по смыслу отдельным лексемам, а свободные словосочетания были представлены в форме валентностных рамок.

Хотя в толковых словарях обычно во внимание принимается несколько критериев (лексическая ограниченность, воспроизводимость некоторой конструкции в неизменном виде и др.), граница между свободными и устойчивыми (фразеологизированными) словосочетаниями устанавливается довольно субъективно. Критерии разграничения свободных и устойчивых сочетаний регулярно нарушаются. Например, фактор лексической ограниченности зачастую вступает в противоречие с регулярными примерами «вариантов» фразеологизмов (таких как: *бросаться, кидаться, лезть в глаза*) заполнения как активной, так и пассивной позиции.

Ассоциативный словарь (Караулов и др. 2002) также регулярно приводит элементы устойчивых словосочетаний среди наиболее устойчивых (частых) реакций (например, реакция *в долгу* для *оставаться* с частотой 19), что дополнительно указывает на то, что такая информация активно используется в языковой модели человека.

⁵ Kunze C., Naumann K. GermaNet homepage. <http://www.sfs.uni-tuebingen.de/lsd>

Однако, установить четкую зависимость между частотой реакции и характеристикой устойчивости сочетания не представляется возможным, что не позволяет нам использовать данные ассоциативного словаря непосредственно.

Таким образом, в работе над RussNet мы вынуждены опираться прежде всего на данные, полученные при статистической обработке корпуса текстов. Для проведения контекстного анализа нами используется корпус-менеджер Бонито⁶, встроенные функции которого позволяют нам вычислять различные показатели взаимной встречаемости единиц в текстах. Эффективным способом выявления компонентов устойчивых сочетаний является блок статистик, в котором для указанного диапазона контекстов («окна»), задаваемого количеством слов, вычисляются параметры, абсолютной $freq(x,y)$ и относительной $freq(x,y)/N$ частоты сочетания слов, Т-коэффициент и коэффициент MI (mutual information, коэффициент взаимной зависимости):

$T(x, y) = \frac{freq(x, y) - \frac{freq(x) \cdot freq(y)}{N}}{\sqrt{freq(x, y)}}$	$MI(x, y) = \log_2 \frac{freq(x, y) \cdot N}{freq(x) \cdot freq(y)}$
--	--

Наиболее информативным является последний показатель. В отечественной традиции ему соответствует коэффициент «неслучайности», который широко использовал Н.Д. Андреевым (Андреев) для автоматического выделения морфем и морфоподобных сегментов. Он предполагал, что у коэффициента есть интервал значений, которые помогают выявить осмысленные языковые единицы. Значения интервала необходимо подбирать, поскольку на разных уровнях языковой структуры соотношения частот имеют собственную структуру.

Ниже в Таблице 1 приводятся значения статистических показателей, полученные с помощью Бонито, для контекстов глагола *набрать* в окне, состоящем из 1, 2 и 5 слов.

word	MI-score	T-score	Rel. f [%]	Abs. f
номер	10.38/ 10.66/ 10.86	7.478/ 8.241/ 8.827	4.505/ 5.471/ 6.275	56/ 68/ 78
в	1.47/ 1.955/ 2.718	4.041/ 5.553/ 8.265	0.0094/ 0.0131/ 0.0222	40/ 56/ 95
две	6.832/ 6.832/ 6.925	3.839/ 3.839/ 3.967	0.3851/ 0.3851/ 0.4108	15/ 15/ 16
воды	6.465/ 6.687/ 7.339	3.425/ 3.705/ 4.661	0.2985/ 0.3483/ 0.5473	12/ 14/ 22
скорость	8.615/ 9.156/ 9.243	3.308/ 3.993/ 4.116	1.325/ 1.928/ 2.048	11/ 16/ 17
полную	8.959/ 8.959/ 9.111	2.994/ 2.994/ 3.157	1.682/ 1.682/ 1.869	9/ 9/ 10
силу	7.269/ 7.421/ 7.559	2.981/ 3.144/ 3.299	0.5214/ 0.5794/ 0.6373	9/ 10/ 11
побольше	9.255/ 9.255/ 9.618	2.641/ 2.641/ 2.996	2.065/ 2.065/ 2.655	7/ 7/ 9
телефон	8.156/ 8.349/ 8.349	2.636/ 2.82/ 2.82	0.9642/ 1.102/ 1.102	7/ 8/ 8
на	1.285/ 1.639/ 2.67	2.502/ 3.256/ 5.778	0.0083/ 0.0105/ 0.02151	18/ 23/ 47
высоту	9.421/ 9.643/ 9.643	2.446/ 2.642/ 2.642	2.317/ 2.703/ 2.703	6/ 7/ 7
воздуха	7.526/ 7.749/ 9.189	2.436/ 2.633/ 4.351	0.6231/ 0.7269/ 1.973	6/ 7/ 19

Таблица 1. Статистические характеристики контекстов слова *набрать* (размер окна -1,+1; -2,+2; -5,+5 слов)

Как видно из таблицы, высокие показатели MI и T выделяют как слова, являющиеся контекстными маркерами (*воды, воздуха, скорость, высоту, номер, телефон*), так и слова, не ассоциирующиеся со значениями глагола (*две, побольше, на*). Динамика изменения показателей при расширении окна указывает, что быстро меняющиеся значения свидетельствуют о случайном попадании в окно анализа частотных слов, стабильный прирост значений – о контекстных маркерах со слабо фиксированной позицией, практически стабильные значения отмечают устойчивые позиционно-связанные элементы контекста. Последняя характеристика связана еще с одной особенностью устойчивых словосочетаний – они приближаются в структурном плане к составным лексемам, тяготея к непроницаемости, т. е. к контактному расположению компонентов. Действительно, расположение компонентов устойчивых оборотов *большой палец, иметь в виду* показывают практически абсолютную контактность, которую в первом случае может разрывать только ряд (*большой и указательный пальцы*), а во втором – наречия (*имея также в виду*). Более того, если устойчивое словосочетание разрывается, меняет значение составного целого (*большой волосатый палец*).

Проблемой является то, что как в отношении лексической избирательности, так и контактности наблюдается не простая дихотомия (контактно-дисконтактно), а целая шкала возможных соотношений компонентов словосочетания в контексте.

Например, контексты глагола *набрать* в значении 'вздохнуть' составляют только 3% от общего числа контекстов в нашем корпусе. Контекстным маркером данного значения является генитив *воздуха*, который может быть расположен как контактно, так и после указания части тела человека (*в грудь, в легкие, полную грудь, полные легкие*). Если первый маркер является абсолютно обязательным, т.е. реализуется в 100% контекстов, то второй – в 88%. Глагол *вздохнуть* в синонимичном значении имеет несколько иную структуру контекстных маркеров: упо-

⁶ Rychly, Smrz 2004. См. также Bonito homepage: <http://nlp.muni.cz/projects/bonito>

минание воздуха не встречается, зато регулярно появляется наречие, характеризующее силу вдоха (*глубоко, широко, коротко*), или указание части тела (*полной грудью*). Регулярно наречные выражения при глаголе *вздохнуть* указывают на эмоциональное состояние человека и являются контекстными маркерами для наиболее частотного значения глагола: 'сделать вдох и выдох, выражая некоторое чувство' (*вздохнуть облегченно, с облегчением, разочарованно, устало, страдальчески*). Таким образом, именно сочетание *набрать воздуха* входит в синсет *вздохнуть*.

В некоторых случаях сочетание слов может использоваться и как устойчивое, и как свободное. Например, *большой дом* используется как устойчивое словосочетание в качестве топонима *Большой Дом* (при этом компоненты словосочетания всегда расположены контактно) или как свободное сочетание, но тогда компоненты могут разрываться (*...жил он размеренно и однообразно, недалеко от института, в большом вычурном доме эпохи так называемых архитектурных излишеств*).

Дальнейшие направления работы

Одной из наиболее сложных надстроек Bonito является так называемый Skecht Engine – программа для вычисления «словесных описаний» (Word Sketches) на основе морфологически размеченного корпуса и заранее заданных типов грамматических конструкций (например, V + N3). В случае с RussNet эти грамматические конструкции соответствуют грамматическим характеристикам валентностных рамок. Таким образом, используя наш корпус, мы можем автоматически извлекать лексические наполнения всех реализованных в тексте валентностных рамок для интересующих нас слов, проводить их статистический анализ, на основе полученных данных оценивать значимость (обязательность/факультативность) валентностей, сравнивать описания для различных лексических единиц, и устанавливать семантические отношения между ними.

Литература

- Азарова и др.* Компьютерный тезаурус русского языка типа WordNet // Труды Международной конференции Диалог-2003. М., 2003. С. 43–50
- Azarova et al.* RussNet: Building a Lexical Database for the Russian Language. In: Proceedings: of the Workshop on WordNet Structures and Standardisation, and how these affect Wordnet Application and Evaluation. Las Palmas, Spain, 2002. pp. 60–64.
- Stranakova-Lopatkova M., Zabokrtsky Z. Valency Dictionary of Czech Verbs: Complex Tectogrammatical Annotation. In: Proceedings of LREC-2002. Las Palmas, Spain, 2002. pp. 949-956.
- Agirre E., Martinez D. Integrating Selectional Preferences in wordnet. In: Proceedings of the GWC-2002. Mysore, India, 2002.
- Bentivogli L., Pianta E. Extending WordNet with Syntagmatic Information. In: Proceeding of the 2nd Global WordNet Conference. Brno, Czech Republic, 2004. pp. 47-53.
- Baker C.F., Fillmore C. J., Lowe J. B. The Berkeley FrameNet Project. In: Proceedings of the COLING/ACL 1998. Montreal, 1998. pp. 86–90.
- Rychly P., Smrz P. Manatee, Bonito and Word Sketches. In: Proceedings of the 2nd International Conference on Corpus Linguistics (Corpora-2004). St.Petersburg, 2004. pp. 116-121.
- Sag I., Baldwin T., Bond F., Copestake A., Flickinger D. Multiword Expressions: A Pain in the Neck of NLP. In: Proceedings of the CILING 2002. Mexico City, Mexico, 2002.
- Calzolari N., Fillmore C., Grishman R., Ide N., Lenci A., McLeod C., Zampolli A. Towards Best Practice for Multiword Expressions in Computational Lexicons. In: Proceedings of LREC 2002. Las Palmas, Spain, 2002.
- Fellbaum C. Towards a Representation of Idioms in WordNet. In: Proceedings of the Workshop on Usage of WordNet in Natural Language Processing Systems, COLING/ACL. Montreal, 1998. pp. 52-57.
- Fellbaum C. (ed.) WordNet: WordNet: An electronic lexical database. Cambridge, Mass.: MIT Press, 1998.
- Караулов Ю.Н., Черкасова Г.А., Уфимцева Н.В., Сорокин Ю.А., Тарасов Е.Ф. Русский ассоциативный словарь. Т. 1. От стимула к реакции. М., 2002.