

АВТОМАТИЗАЦИЯ ПОСТРОЕНИЯ АНГЛО-РУССКОГО WORDNET

A.M. Сухоногов

*Петербургский Университет путей
сообщения, кафедра ИВС
ASukhonogov@rambler.ru;*

C.A. Яблонский

*Петербургский Университет путей
сообщения, кафедра ИВС,
ЗАО “Руссикон”
serge_yablonsky@hotmail.com; info@russicon.ru*

Целью настоящей работы является описание построения русской версии WordNet и методов автоматизированного создания межъязыкового индекса для англо-русской версии WordNet.

1. Введение

Работа над словарем Princeton WordNet (PWN) [1,2] английского языка начата в Принстонском университете (США) в начале 80-х годов и продолжается сегодня. Сейчас доступна версия 2.0. этого словаря. Существующая версия WordNet охватывает более 120 тысяч слов общеупотребительной лексики современного английского языка. За период с марта 1996 по сентябрь 1999 года при финансировании Европейской комиссии был создан многоязычный вариант WordNet – EuroWordNet [3]. Эта лексическая система объединила в себе WordNet английского, датского, испанского, итальянского, немецкого, французского, чешского и эстонского языков, а за основу был взят Принстонский WordNet версии 1.5. Национальные версии проекта связаны с исходным PWN 1.5 и между собой через специальный межъязыковой индекс (Interlingual Index – ILI(PWN 1.5)). В 2004 году завершена работа над проектом BalkaNet, объединяющим греческий, болгарский, турецкий, чешский, французский, румынский и сербский языки. Поскольку в проекте за основу была взята версия 2.0 PWN, в BalkaNet межъязыковой индекс базируется на PWN 2.0 – ILI (PWN 2.0).

В настоящее время известно о нескольких реализациях WordNet подобных лексических баз данных для русского языка:

- Проект RussNet, разрабатывается с 1999 года на филологическом факультете СПбГУ [4]. Методика и принципы построения словаря проекта RussNet ориентированы на длительный процесс разработки ресурса группой лингвистов без автоматизации процесса построения и связи с исходным PWN.
- Проект тезауруса RuThes, используемого в УИС РОССИЯ [5]. Закрытый коммерческий ресурс. Рассматриваемая в работе реализация русской версии WordNet (Russian WordNet - RWN) [6-10] ориентирована на формирование ядра RWN (более 100 тыс. слов) за счет
 - привязки RWN к PWN;
 - использования доступных русских, англо-русских и русско-английских словарей,

- автоматизации процедур построения и редактирования RWN.

Целью настоящей работы является описание

- построения русской версии WordNet,
- методов автоматизированного построения межъязыкового индекса для англо-русской версии WordNet¹.

2. Краткое описание проекта RWN

Разработка RWN включает (рис.1):

- построение русской версии WordNet, достаточно полно (100-120 тыс. лексических единиц) описывающей лексику русского языка и сопоставимой по числу лексических единиц с английской версией. Для этого используются морфологический анализатор и лексические ресурсы [11] ЗАО “РУССИКОН”², словари, свободно распространяемые в Интернете, (<http://www.slovarik.ru/>, <http://www.artint.ru/projects/frqlist.asp>), и ряд печатных изданий;
- интеграцию с другими лексическими системами на основе использования технологии Semantic Web.
- программное построение межъязыкового индекса, определяющего соответствие между синсетами PWN и RWN, на основе использования электронных версий словарей издательства Oxford Press³, ряда доступных в Интернете англо-русских и русско-английских словарей, WordNet-Domains [12].

¹ Для выполнения части данной работы (перевод 20000 синсетов PWN) авторским коллективом в 2005 году получен грант ЗАО “Яндекс” № 103003 - «Построения межъязыкового индекса...».

² ЗАО “Руссикон” (www.russicon.ru) предоставило для создания версии WordNet для русского языка лингвистические ресурсы и программы.

³ Научный коллектив из сотрудников ПГУПС (кафедра ИВС) и ЗАО «Руссикон» выиграл в 2003 году конкурс издательства Oxford Press на лучший исследовательский проект по использованию словарей Oxford Press. В настоящее время издательства Oxford Press предоставило

2.1. Построение RWN

В WordNet словарными статьями являются синсеты – множества слов-синонимов, обозначающих один и тот же концепт в заданном контексте. Для синсета явно указывается часть речи и толкование. Каждое слово, входящее в состав синсета, может дополнительно иметь ряд атрибутов, например, признак доминантности, пометы типа «идиома», «близкое значение» и т.д. Для каждого слова может быть приведен пример его употребления в заданном контексте – определяется набор речений и фразеологизмов, также определяются толкования.

В настоящее время (по состоянию на май 2005г.) RWN включает:

- 55397 существительных, образующих 71729 синсет;
- 34400 глаголов, образующих 44998 синсет;
- 25315 прилагательных, образующих 33571 синсет;
- 10071 наречий, образующих 9716 синсетов;
- парадигмы для всех лемм словарника;
- словообразовательные отношения;
- выделенную из EuroWordNet Top Ontology, с возможностью расширения;
- WordNet Domains с возможностью определения новых доменов.

Для проекта RWN разработаны методы и программные средства, позволяющие значительно сократить время разработки (рис. 1).

Так разработан редактор TenDrow для редактирования WordNet и пакет специальных утилит построения WordNet и III-индекса.

В настоящее время редактор TenDrow (рис. 2)

- работает с СУБД Oracle9i/10g и Interbase/Firebird;
- осуществляет обмен данными между БД и OWL-представлением WordNet (экспорт / импорт данных);
- поддерживает форматы лексических файлов Princeton WordNet 2.0 и VisDic1.3.36 (для загрузки в БД).

Редактор TenDrow предназначен для создания и редактирования широкого класса тезаурусов и близких к ним структур.

Схема данных Russian WordNet, позволяющая представить любую структуру WordNet-подобного словаря рассматривается в работе [8].

для создания русской версии WordNet XML версии следующих словарей: Oxford Russian Dictionary, 3^d Edition, New Oxford Dictionary of English, 2nd Edition, New Oxford Thesaurus of English.

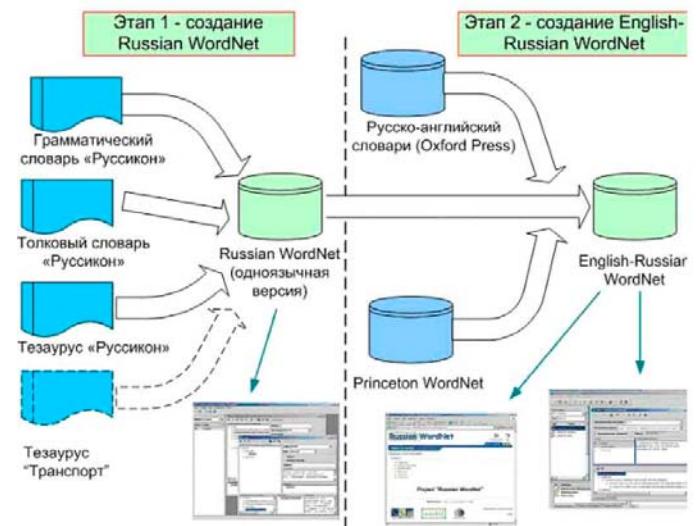


Рис. 1. Основные этапы создания Russian WordNet

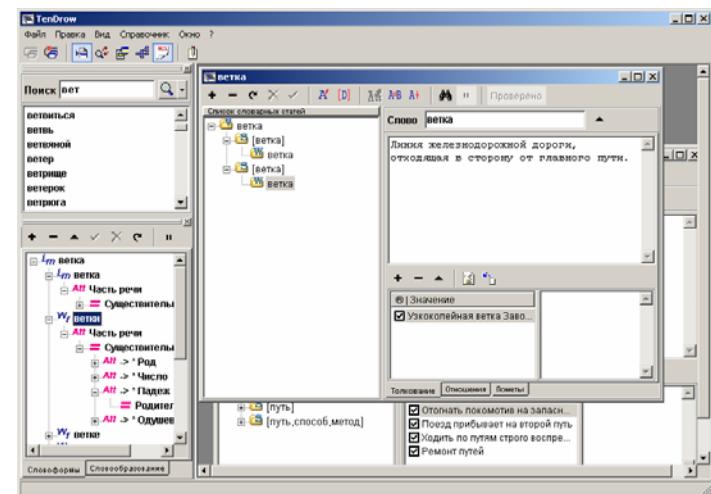


Рис. 2. Редактор TenDrow. Основное рабочее окно

Данные проекта хранятся и обрабатываются в СУБД Oracle9i/10g, что позволяет:

- организовать многопользовательский доступ к данным;
- открыть доступ к текущему состоянию проекта всем членам коллектива разработчиков;
- осуществлять резервирование данных средствами СУБД;
- достаточно просто реализовывать загрузку / выгрузку данных в различные форматы (TXT, XML, OWL, лексические файлы Princeton WordNet и т.д.).

Вид интерфейса для просмотра базы данных WordNet в Интернете приведен на рис. 3.

2.2. Представление WordNet в Semantic Web

В рамках технологии Semantic Web консорциум W3C разрабатывает стандарт представления WordNet, в котором WordNet представляется как фрагмент описания онтологии. Для этого словарь достаточно представить в формате описания RDF и обеспечить совместный доступ к этому ресурсу для распределенных программ – агентов. Формат OWL принят в качестве основного для экспорта и импорта данных в/из базы данных в проекте Russian WordNet. OWL/RDFS-схема Russian WordNet соответствует основным рекомендациям W3C-консорциума. OWL-схема проверена на корректность с помощью RDF-анализатора Jena (<http://www.w3.org/TR/2003/PR-rdf-schema-20031215>).

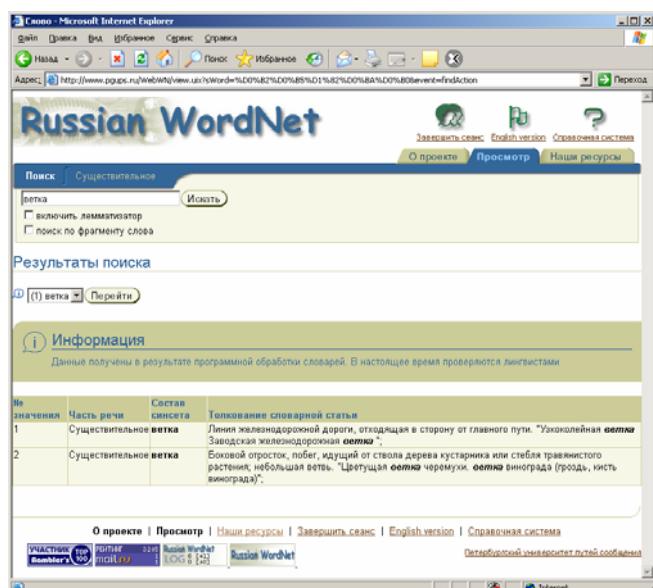


Рис. 3. Сайт проекта Russian WordNet (<http://www.pgups.ru/WebWN/wordnet.uix>)

Пример экспортированного из системы варианта WordNet (Princeton WordNet 2.0) в формате OWL доступен на сайте проекта. Таким образом, русский WordNet может использоваться и как один из компонентов технологии W3C/SemanticWeb.

3. Автоматизированное построение межязыкового индекса

В проекте EuroWordNet впервые была осуществлена попытка объединения WordNet для нескольких европейских языков вместе с Princeton WordNet с помощью межязыкового индекса ILI (PWN1.5). Индекс позволяет находить аналоги английских синсетов на других языках, а также обеспечивает доступ к 63 сущностям верхнего уровня онтологии (top-ontology) PWN. Эта top-ontology определяет общую для всех языков

семантическую сеть, что обеспечивает связь между версиями WordNet для различных языков.

В проекте BalkaNet наряду с рассмотрением (PWN1.5) в качестве ILI (PWN 2.0) используется сама версия PWN 2.0.

В проекте RWN решаются две задачи англо-русского и русско-английского перевода WordNet:

- перевод 63 сущностей top-ontology на русский и обратно;
- автоматизированный перевод ILI (PWN 2.0) с помощью электронных версий словарей и разработанных программных средств.

3.1. Исходные данные

Используются

- лексические БД Princeton WordNet 2.0 (PWN) и Russian WordNet (RWN).
- англо-русский и русско-английский Oxford Russian Dictionary, 3^d Edition,
- New Oxford Dictionary of English, 2nd Edition,
- New Oxford Thesaurus of English.
- англо-русские и русско-английские словари, распространяемые по лицензии GPL в составе сервера словарей DICT Server (реализация RFC 2229 [14]) и ряд других словарей, свободно распространяемых в Интернете.
- WordNet Domains [12].
- Англо-русский словарь под ред. Ю.Д. Апресяна.

Словари конвертируются в отдельную схему СУБД. Для словарей определяется API, позволяющее

- для заданного слова находить множество слов – переводов и словарных статей в New Oxford Dictionary of English, 2nd Edition и New Oxford Thesaurus of English,
- по слову-переводу находить множество словарных статей русско-английского словаря (инвертированный словарь).

3.2. Особенности перевода WordNet

Пусть заданы два языка L1 и L2 и слово W_{L2} является переводом слова W_{L1} . При этом будем считать, что выполняется условие совпадения частей речи слов пары $\langle W_{L2}, W_{L1} \rangle$.

Если для каждой пары $\langle W_{L2}, W_{L1} \rangle$ выполняются следующие условия:

- WordNet языка L1 (WN_{L1}) содержит lemmat (W_{L1}) и WordNet языка L2 (WN_{L2}) содержит lemmat (W_{L2}), где функция lemmat (W) преобразует словоформу W в лемму,
- все возможные значения lemmat (W_{L1}) присутствуют в WN_{L1} и все возможные значения lemmat (W_{L2}) присутствуют в WN_{L2} ,

- WN_{L1} и WN_{L2} связаны через ILI-подобный механизм, то возможно связать пару WordNet $\langle WN_{L2}, WN_{L1} \rangle$ для языков L1 и L2 так, что алгоритм связи будет сопоставлять все синсеты WN_{L1} всем синсетам WN_{L2} через ILI.

В общем случае такое отображение невыполнимо, поскольку:

- 1) для некоторого слова W_{L1} может не существовать соответствующего слова W_{L2} , т.е. перевод может отсутствовать,
- 2) число значений lemmat (W_{L1}) может быть не равно числу значений lemmat (W_{L2}) и/или значения могут не совпадать,
- 3) некоторое слово W_{L1} может переводиться не одним словом W_{L2} , а некоторым словосочетанием, не являющимся в общем случае фразеологизмом или устойчивым словосочетанием в языке L2.

Поэтому идеального перевода WordNet с одного языка на другой (в нашем случае с английского на русский) не существует, и алгоритм построения связи PWN и RWN через ILI (PWN 2.0) должен разрешать противоречия 1)-3).

В настоящей работе основное внимание уделяется методу автоматического построения перевода-соответствия PWN и RWN. Этап “ручной” проверки и устранения неточностей и ошибок не рассматривается.

3.3. Порядок построения межъязыкового индекса.

При построении межъязыкового индекса (ILI) ставится задача воспроизведения основных деревьев отношений (гипонимии и меронимии) PWN в RWN. Порядок построения ILI индекса определяется структурой этих деревьев и начинается с корня каждого дерева. При построении ILI осуществляется последовательный обход деревьев гипонимии и меронимии PWN, затем – синсетов, которые не попали ни в одно из этих деревьев. По каждому дереву осуществляется обход в ширину: синсеты – корни дерева, затем – все синсеты 1-го уровня, 2-го уровня и т.д. Обход прекращается при достижении уровня листьев дерева для текущего узла дерева. Такой подход позволяет воспроизвести основные отношения, определенные в PWN.

Согласно принятому порядку построения ILI-индекса, исходным является синсет PWN – s_{PWN} . На первом этапе для этого синсета строится список синсетов-альтернатив из RWN – $S_{RWN} = \{ s_{RWN_1}, s_{RWN_2}, \dots, s_{RWN_n} \}$. Если $S_{RWN} = \{\emptyset\}$, построение ILI для синсета s_{PWN} невозможно, поскольку используемые для перевода словари не содержат ни одного слова или словосочетания из множества слов синсета s_{PWN} . Такие синсеты выделяются и должны быть обработаны вручную. Если $S_{RWN} \neq \{\emptyset\}$, для каждой пары синсетов вычисляется значение оценочной функции $R = R(s_{PWN}, s_{RWN_i})$. На втором этапе для

каждого синсета s_{RWN_i} из S_{RWN} строится свой список синсетов-альтернатив PWN – $S_{PWN} = \{ s_{PWN_1}, s_{PWN_2}, \dots, s_{PWN_m} \}$ и также вычисляется значение оценочной функции $R'_i = R'(s_{RWN_i}, s_{PWN})$. В список S_{PWN_i} каждого синсета-альтернативы из S_{RWN} гарантированно попадает исходный синсет – s_{PWN} , поскольку для перевода используется единый англо-русский и русско-английский словарь.

Основным критерием для определения соответствия исходного синсета s_{PWN} и синсета-альтернативы s_{RWN_i} мы считаем минимальное значение суммы приведенных значений оценочной функции:

$$ILI(s_{PWN}, s_{RWN}) = \min(R_P(s_{PWN}, s_{RWN}) + R'_P(s_{RWN_i}, s_{PWN})) \quad (1), \text{ где}$$

$$R_P = \frac{R(s_{PWN}, s_{RWN_i})}{\sum_{i=1}^n R(s_{PWN}, s_{RWN_i})},$$

$$R'_P = \frac{R'(s_{RWN_i}, s_{PWN})}{\sum_{i=1}^m R'(s_{RWN_i}, s_{PWN})} \quad (2)$$

Для получения корректного соответствия синсетов PWN и RWN необходимо, чтобы значения, для которых строится межъязыковой индекс, были определены как в PWN, так и в RWN. Используемые для перевода словари содержали, по крайней мере, корректный перевод одного из слов синсетов. Совпадение переводов словосочетаний в составе синсетов практически гарантирует их соответствие. В настоящей статье не рассматриваются методики для оценки достоверности полученного результата.

3.4. Порядок построения списка синсетов-альтернатив

Пусть $s = \{w_1, w_2, \dots, w_n\}$ – синсет, для которого требуется построить список S синсетов-альтернатив. Англо-русский и русско-английский словари позволяют получить множества переводов слов синсета: $w_i = \{t_{i1}, t_{i2}, \dots, t_{in}\}$. Для каждого перевода t_{ik} слова w_i исходного синсета s можно построить множество синсетов-альтернатив. Однако, поскольку синсет по определению представляет только одно из значений, только один перевод слова w_i будет представлять значение исходного синсета. Дополнение же списка S синсетами, содержащими другие слова из множества $\{t_{i1}, t_{i2}, \dots, t_{in}\}$ приведет к появлению альтернатив с заведомо иным значением, значительно расширит область поиска, затруднит выбор эквивалентного значения из S с использованием оценочной функции.

Актуальной является задача определения пары $\{w_i, t_k\}$, такой, что t_k представляет наиболее

Таблица 1

вероятный перевод значения синсета s . В случае, если из-за неполноты англо-русского и русско-английского словаря (если отсутствует перевод слова w_i со значением синсета s), пара $\{w_i, t_k\}$ будет определена некорректно. Даже такое соответствие $\{w_i, t_k\}$ приведет лишь к незначительному расширению списка S , эквивалентный исходному синсет попадет в список S при переводе других слов синсета s .

Для определения пары $\{w_i, t_k\}$ используется методика расчета семантического расстояния, основанная на выявлении характерных зависимостей между словами по значениям их условных вероятностей в достаточно большом и представительном корпусе текстов, таком, каким сейчас является Internet. За основу взята формула [13] для определения нормализованного поискового расстояния (также известного как NGD – *normalized Google distance*):

$$NGD(x, y) = \frac{\max \{\log f(x), \log f(y)\} - \log f(x, y)}{\log M - \max \{\log f(x), \log f(y)\}} \quad (3)$$

где M – число web-документов, проиндексированных поисковой системой; для Google на момент написания статьи $M = 8\,058\,044\,651$ страниц; $F(x) = Mp(x)$ – число web-страниц, на которых встречается слово x ; $f(y) = Mp(y)$ – число web-страниц, на которых встречается слово y ; $f(x,y) = Mp(x,y)$ – число web-страниц, на которых одновременно встречаются x и y .

В качестве примера приведем значительно упрощенный, в демонстрационных целях, вариант определения списка S синсетов-альтернатив для следующего синсета PWN:

{carriage, equipage, rig} – a vehicle with four wheels drawn by two or more horses

По слову «carriage» в PWN находится 5 синсетов, в том числе и вышеприведенный. Русско-английский и англо-русский словари дают следующие варианты переводов (упрощено):

carriage – {экипаж, карета}, {пассажирский вагон}, {тележка, вагонетка}, {гондола} и т.д. (всего 20 вариантов перевода);

equipage – предположим, нет перевода;

rig – {приспособление, устройство}, {агрегат, оборудование}, {костюм}, {упряжка, карета} и т.д. (всего 35 вариантов перевода)

Используются доступные интерфейсы поисковых систем, например, Google (<http://www.google.com/apis/>), получаем следующие значения частот (по числу найденных web-страниц) (таблица 1).

Результатом перевода, как видно, не всегда является одно слово. В большинстве случаев, перевод представлен группой слов. Для таких групп, определяется минимальное значение NGD (таблица 3).

$f(x)$		приспособление	устройство	агрегат	оборудование	костюм	упряжка	карета
		147000	1100000	206000	3260000	561000	9420	69000
экипаж	479000	995	50800	4570	81400	33200	600	4860
карета	69000	430	738	317	1510	7640	395	68800
пассажирский вагон	507	42	187	53	326	138	0	50
тележка	159000	546	17700	702	52300	849	112	493
вагонетка	896	145	591	256	806	392	6	42
гондола	195	1	11	0	13	2	0	6

В таблице первый столбец – частоты для переводов “carriage”, первая строка – частоты для переводов “rig” по данным, полученным с использованием Google API. В соответствующих ячейках находятся частоты совместного появления одновременно двух слов на одной web-странице. Например, слова «экипаж» и «устройство» одновременно встречаются на 50800 – web-страницах, «упряжка» и «пассажирский вагон» вообще ни в одном документе вместе не встречаются.

Согласно (3) рассчитывается «семантическое расстояние» между словами-переводами, таблица 2.

Таблица 2

$NGD(x,y) * 10^3$	приспособление	устройство	агрегат	оборудование	костюм	упряжка	карета
экипаж	30.33	11.89	20.86	13.49	11.41	33.94	20.51
карета	31.84	35.46	35.65	34.26	18.63	29.31	0.06
пассажирский вагон	54.7	46.55	53.24	45.48	46.92	-	49.29
тележка	30.34	16.76	29.53	15.39	32.02	44.02	31.11
вагонетка	41.18	37.09	37.57	38.57	37.79	76.09	51.44
гондола	-	83.67	-	84.35	140.05	-	86.07

Таблица 3

$NGD(x,y) * 10^3$	приспособление, устройство	агрегат, оборудование	костюм	упряжка, карета
экипаж, карета	11.89	13.49	11.41	0.06
пассажирский вагон	46.55	45.88	49.92	49.29
тележка, вагонетка	16.76	15.39	32.02	31.11
гондола	83.67	84.35	140.05	86.07

Здесь минимальное семантическое расстояние зафиксировано для переводов {упряжка, карета} и {экипаж, карета}. Исходя из этого, список S будет состоять из следующих синсетов RWN:

{упряжка} – несколько лошадей, собак, оленей и т.п., запряженных одной упряжью;

- {упряжка, упряжь} – совокупность приспособлений, предметов для запряжки лошадей или другой живой тяги;
- {карета} – закрытый со всех сторон четырехколесный конный экипаж на рессорах;
- {повозка, экипаж} – колесный безрессорный экипаж простого устройства, а также общее название различных колесных экипажей;
- {экипаж} – команда, личный состав корабля, самолета, танка а также состав специалистов, обслуживающих какой-либо движущийся механизм;
- {экипаж} – береговая воинская часть морской пехоты, часто служащая для пополнения флотских команд.

3.4. Порядок вычисления оценочной функции

Оценочная функция $R = R(s_{WN1}, s_{WN2})$ строится для определения оценки степени соответствия синсетов из словарей WordNet русского и английского языков (WN_{L2}, WN_{L1}), алгоритм её расчета и формула, в общем, подобны (3) для расчета нормализованного поискового расстояния. Дополнительно оценивается соответствие:

- перевода слова синсета и слова синсета-альтернативы;
- перевода слова синсета и лемм толкования синсета-альтернативы;
- перевода лемм толкований синсета и слова синсета-альтернативы;
- перевода лемм толкований синсета и лемм толкования синсета-альтернативы;
- слова и толкования синсета-альтернативы и синсета, который был включен в состав ILI и является родительским в дереве гипонимии/меронимии по отношению к рассматриваемому.
- учитываются стилистические пометы и соответствия, определенные для синсета в WordNet Domains[12].

Перед вычислением значения оценочной функции выполняется предварительная обработка всех синсетов:

- толкования синсетов разбиваются на слова. Для каждого из слов определяется лемма. Для толкований синсетов PWN используется лемматизатор, входящий в состав DICT Server, для толкований синсетов RWN используется лемматизатор ЗАО «Руссикон». Набор лемм заменяет исходные словоформы в толковании синсета на время вычисления индекса. Из набора лемм исключаются леммы, образующие перевод слова синсета. С помощью словарей переводятся все леммы, полученные из толкований синсетов.
- для каждого синсета определяется частота/вероятность. Эти значения определяются по статистике, полученной от поисковых систем (Yandex, Google) по методике, описанной выше. Для PWN

дополнительно используются частоты, приведенные в составе WordNet sense_key.

Список литературы:

1. Fellbaum C. WordNet: an Electronic Lexical Database. MIT Press, Cambridge, MA, 1998.
2. Miller G. et al. Five Papers on WordNet. CSL-Report, vol.43. Princeton University, 1990. <ftp://ftp.cogsci.princeton.edu/pub/wordnet/5papers.ps>
3. Vossen, P. EuroWordNet: A Multilingual Database with Lexical Semantic Network. Dodrecht: Kluwer, 1998.
4. Сайт проекта RussNet http://www.phil.pu.ru/depts/12/RN/index_ru.shtml.
5. Портал УИС «Россия» <http://www.cir.ru/>.
6. Balkova V., Suhonogov A., Yablonsky S.A. Russia WordNet. From UML-notation to Interne/Intranet Database Implementation, In: *Proceedings of the Second International WordNet Conference, GWC 2004.* – Brno, Czech Republic, 2004, pp. 31-38.
7. Yablonsky S.A. Integration of Russian Language Resources. In: *Proceedings 4th International Conference on Language Resources & Evaluation.* – Barselona, Spain, 2004.
8. Сухоногов А.М., Яблонский С.А. Разработка русского WordNet. – Электронные библиотеки: перспективные методы и технологии, электронные коллекции: Труды шестой всероссийской научной конференции RDCL'2004, Пущино, 2004. – стр. 113-117.
9. Сухоногов А.М., Яблонский С.А. Словари типа WordNet в технологиях Semantic Web. – Девятая Национальная конференция по искусственному интеллекту с международным участием КИИ-2004. Труды конференции. В 3-х т., Т.2. М.:Физматлит, 2004. – стр. 557-564.
10. Сухоногов А.М., Яблонский С.А. Использование WordNet при поиске и индексации текстов.- Международная конференция «Корпусная лингвистика - 2004»: Тезисы докладов. – СПб., 2004. – стр. 84-89.
11. Yablonsky S.A. Russicon Slavonic Language Resources and Software. In: A. Rubio, N. Gallardo, R. Castro & A. Tejada (eds.) *Proceedings First International Conference on Language Resources & Evaluation*, (pp. 1141–1147). – Granada, Spain, 1998.
12. Magnini B., Cavaglia B. Integrating Subject Field Codes into WordNet // Proceedings of LREC-2000, Second International Conference on Language Resources and Evaluation / M. Gavrilidou, G. Crayannis, S. Markantonatu, S. Piperidis, G. Stainhaouer (eds.). – Athens, Greece, 31 May – 2 June, 2000. – P. 1413–1418.
13. Rudi Cilibarsi, Paul Vitanyi Automatic Meaning Discovery Using Google, <http://www.arxiv.org/abs/cs.CL/0412098>.
14. RFC2229 – A Dictionary Server Protocol,
15. <http://www.faqs.org/rfcs/rfc2229.html>