



119270, Москва, Лужнецкая наб., д. 6,
стр.1, офис 214, ООО «ЭР СИ О»
Тел./факс: (495) 287-98-87
E-mail: info@rco.ru
<http://www.rco.ru>

**Руководство администратора
RCO Ling – пакет настройки семантических
словарей**

Версия 3.0
(Microsoft Windows)

Москва, 2007

В содержание данного документа могут быть внесены изменения без предварительного уведомления. Названия организаций, имена и даты, используемые в качестве примеров, являются вымышленными, если не оговорено обратное.

© ООО «ЭР СИ О», 2007. Все права защищены.

ЭР СИ О, Russian Context Optimizer, RCO являются охраняемыми товарными знаками.

ООО «ЭР СИ О» может являться правообладателем патентов и заявок, поданных на получение патента, товарных знаков и объектов авторского права, которые имеют отношение к содержанию данного документа.

Предоставление вам данного документа не означает передачи какой-либо лицензии на использование данных патентов, товарных знаков и объектов авторского права, за исключением использования, явно оговоренного в лицензионном соглашении ООО «ЭР СИ О».

Все другие названия юридических лиц и изделий являются охраняемыми товарными знаками или товарными знаками, принадлежащими их владельцам.

Содержание

RCO Ling – пакет настройки семантических словарей	4
Обзор.....	4
Введение	5
Словарь моделей управления	6
Тезаурус-классификатор	7
Словари общеупотребительной лексики.....	8
Установка пакета RCO Ling	9
Работа с пакетом RCO Ling	10
Подключение словарей: файл lingdic.ini	10
Файлы-гlossарии: linglexclass.txt, lingroles.txt, lingconnectors.txt.....	11
Настройка словаря моделей управления	11
Настройка тезауруса-классификатора	12
Настройка словарей общеупотребительной лексики.....	14
Сборка словарей – приложение LingDicCompiler	14
Приложение 1. Используемые обозначения	16

RCO Ling – пакет настройки семантических словарей

Обзор

В этом руководстве содержатся основные сведения по настройке семантических словарей, которые используются в продуктах линейки **RCO** при анализе текста.

Целевой бинарный словарь **LingDct.dat**, используемый в программах **RCO** для высокоэффективной работы, собирается из исходных текстовых файлов словаря при помощи программ, входящих в настоящий пакет. Специфика предметной области, в которой работают приложения **RCO**, может потребовать расширения словарей или изменения принятой системы семантической классификации. Для этих целей и предназначен данный пакет.

Для выполнения установки пакета **RCO Ling** необходимо располагать компьютером с установленной операционной системой **Microsoft Windows NT версии 4.0** и выше.

Введение

Настоящие словари используются при анализе русского текста в продуктах **RCO**. Система словарей описывает различные типы семантических отношений между понятиями текста и способы их синтаксической реализации в тексте, а также позволяет отождествить близкие по смыслу слова-синонимы.

В состав комплекта словарей для семантического анализа входят:

- [словарь моделей управления](#) объемом более 15 тысяч слов;
- [тезаурус-классификатор](#) объемом более 70 тысяч слов;
- [словари общеупотребительной лексики](#) объемом более 10 тысяч слов.

Словарь моделей управления

Общий словарь моделей управления **RCO** используется при синтаксическом анализе текста и включает в себя свыше пятнадцати тысяч наиболее употребительных предикатов русского языка (глаголов, отглагольных существительных и прилагательных, предикативов).

Ниже приведен фрагмент словаря, который описывает ситуацию «аренда», семантические роли ее участников (объект, субъект, источник и т.п.) и способы их грамматического выражения в тексте.

```
арендовать noun В Объект // предмет аренды
арендовать noun И Субъект // арендатор
аренда noun Р Объект // предмета аренды
аренда noun Т Субъект // арендатором
аренда, арендовать noun за В Цена // за цену
аренда, арендовать noun на В Время // на срок
аренда, арендовать noun у Р Источник // у арендодателя
аренда, арендовать noun для Р Назначение // для торговли
```

В строке словаря после каждой группы слов-предикатов с указанием типа управления задается предлог или союз (если таковой имеется) и падеж, в котором должно стоять в тексте подчиненное предикату слово (если это существительное или прилагательное). Далее указываются семантическая роль подчиненного слова и возможные комментарии.

Тип управления обозначает класс зависимых слов – существительное, прилагательное, глагол в инфинитивной или в личной форме. В приведенном примере все предикаты управляют существительными (именными группами).

Дополнительно в модели управления для повышения точности синтаксического анализа текста можно перечислить семантические категории, которым должны удовлетворять слова-аргументы предиката. Например, в модели управления

```
арендовать noun И Субъект CAT: name;men name;office animated
```

обозначения “name;men”, “name;office” и “animated” указывают, что в качестве субъекта глагола «арендовать» в именительном падеже могут выступать слова категорий: «*имя собственное*» вместе с категорией «*человек*», «*имя собственное*» вместе с категорией «*организация*» или категории «*одушевленное*». Это соответствует любым наименованиям физических и юридических лиц и всем одушевленным существительным.

Специфика предметной области, в которой работают приложения информационного поиска, может потребовать расширения словаря и изменения классификации типов семантических ролей. Так, может возникнуть необходимость замены общих названий ролей «*субъект*», «*объект*» и «*источник*», выделяемых в словаре для широкого класса действий, на более частные, характеризующие ситуацию аренды: «*арендатор*», «*предмет аренды*» и «*арендодатель*».

Тезаурус-классификатор

Тезаурус русского языка используется для отождествления близких по смыслу единиц текста и их семантической классификации в ходе анализа документов.

Тезаурус **RCO** позволяет описать два типа семантических отношений между словами: синонимические и гипонимические (общее-частное).

Тезаурус представляет одноуровневую иерархию, в которой слова (или целые синонимические ряды) могут объединяться под обобщающими понятиями – гиперонимы. Все слова, имеющие одно обобщающее понятие, носят название гипонимов.

Ниже приведен пример фрагмента тезауруса, описывающий семантическое поле, связанное с понятием воровства. Как видно, три синонимических ряда, соответствующие понятиям «воровать», «воровство» и «вор», объединены под обобщающим понятием-гиперонимом «воровство». При этом все члены синонимических рядов «воровство» и «воровать» будут отнесены к семантическим категориям, обозначенным как *act* и *pres* – действие и передача материального объекта.

Verb воровать, красть, тырить, ... воровство CAT: act;pres
 Noun воровство, кража, татьба CAT: act;pres
 Noun вор, жулье, жулик, воруга, воровка, воришка воровство

Синонимы и гиперонимы, указанные в тезаурусе, используются для отождествления близких по смыслу единиц текста в ходе синтактико-семантического анализа и приведения их к унифицированному виду при синтезе текста. Например, синтагмы «украдена коварными жуликами» и «коварная воровка крадет» посредством синонимических замен будут преобразованы к виду «коварный вор ворует», а затем, путем приведения к обобщающему гиперониму, примут форму «воровство коварным воров».

В состав тезауруса общей лексики русского языка, включенного в **RCO**, вошло около 75 тысяч слов, объединенных в 22 тысячи гипонимических рядов (22 тысячи гиперонимов), в том числе 17 тысяч синонимических рядов, охватывающих 45 тысяч слов.

Словари общеупотребительной лексики

Дополнительно в состав комплекта семантических словарей для анализа текста входят словари с удаляемыми и общеупотребительными словами русского языка. Данные словари используются в качестве фильтров при отождествлении близких по смыслу единиц текста и при выделении значимых элементов текста в ходе синтактико-семантического анализа.

Удаляемые слова

Слова данного типа, в зависимости от части речи, к которой они относятся, обрабатываются при анализе текста следующим образом:

- прилагательные удаляются из всех конструкций текста, позволяя отождествить близкие по смыслу конструкции. Например, именная группа *«покупка всех аналогичных товаров»* будет преобразована в *«покупка товара»*, если прилагательные *«весь»* и *«аналогичный»* указаны в числе удаляемых слов;
- все текстовые конструкции, которые содержат существительные и глаголы, указанные в числе удаляемых слов, не выделяются в качестве значимых элементов текста. Например, если слово *«отклонить»* входит в число удаляемых, то из текста *«парламент отклонил проект закона ...»* не будут выделены элементы *«отклонение»*, *«отклонение проекта закона»* и *«отклонение парламентом»*, однако выделятся прочие элементы: *«парламент»*, *«проект закона»*, *«проект»*, *«закон»*.

В стандартные словари включено более 3-х тысяч удаляемых слов.

Общеупотребительные слова

Слова данного типа имеют слишком широкое значение, чтобы характеризовать тематику текста в отдельности, без сочетания с другими словами. Например, слова *«использование»* и *«делать»* сами по себе ничего не говорят о содержании текста, но могут оказаться информативными в сочетаниях *«использование химического оружия»*, *«делать деньги»*.

Все текстовые конструкции, содержащие данные слова, выделяются в качестве значимых элементов, только когда они содержат еще хотя бы одно не общеупотребительное и не удаляемое слово. Например, если слова *«концепция»* и *«развитие»* входят в число общеупотребительных слов, то из фрагмента текста *«концепция развития сельского хозяйства»* не выделятся элементы *«концепция»*, *«развитие»*, *«концепция развития»*, но выделятся *«концепция развития сельского хозяйства»* и *«развитие сельского хозяйства»*, так как эти элементы содержат не общеупотребительные слова. И конечно, выделятся *«сельское хозяйство»*, *«хозяйство»* и *«село»*.

В стандартные словари включено более 7-ми тысяч общеупотребительных слов.

Установка пакета RCO Ling

Для установки пакета просто скопируйте все файлы дистрибутива в папку **RCO Ling** или любую иную папку на вашем компьютере.

В состав пакета входят следующие файлы:

lingdic.ini	файл с перечнем исходных текстовых словарей, используемых для сборки бинарного словаря LingDct.dat
*.txt	набор исходных текстовых файлов словарей, перечисленных в файле lingdic.ini
lingexclass.txt, lingroles.txt, lingconnectors.txt	глоссарии используемых в словарях обозначений
LingDct.dat	бинарный файл семантического словаря, создаваемый из текстовых файлов при помощи приложения-компилятора LingDicCompiler.exe
LingDicCompiler.exe	компилятор бинарного словаря – консольное приложение
RCOLing.pdf	файл настоящего руководства

Работа с пакетом RCO Ling

Стандартные семантические словари, входящие в состав лингвистического обеспечения **RCO**, хранятся в текстовом виде в файлах, которые перечислены в файле **lingdic.ini**. Все эти файлы находятся в базовой папке установки **RCO Ling**. Утилита **LingDicCompiler.exe**, запускаемая из этой же папки, собирает из текстовых файлов бинарный файл **LingDct.dat**, который используется продуктами **RCO** при анализе текста.

Для настройки словарей следует ввести или удалить требуемые слова в текстовых файлах при помощи текстового редактора, после чего запустить **LingDicCompiler.exe**. В ходе сборки выдается серия сообщений (файл **errors.txt**), которые позволяют ликвидировать конфликты в словарях, возникающие при связывании слов между собой, а также при стыковке с модулем морфологического анализа.

Пополнение словарей новой лексикой может потребовать сопутствующего расширения словаря морфологического модуля. В этом случае следует обратиться к документации «*RCO Morph – пакет настройки морфологического словаря*».

Подключение словарей: файл lingdic.ini

Файл **lingdic.ini** содержит список файлов словарей, участвующих в сборке, с указанием типа словаря. При подключении новых файлов их имена и тип следует добавить в список.

Формат файла

Каждая строка файла имеет вид:

```
(deleted | common | class | control) : <имя файла>
```

Ключевые слова

Данные слова указывают тип словаря:

- *deleted* – удаляемые;
- *common* – общеупотребительные;
- *class* – тезаурус-классификатор;
- *control* – модели управления.

Комментарии

Знак “//” обозначает начало комментария, который продолжается до конца строки.

Пример файла lingdic.ini

```
deleted: deleted_adj.txt // удаляемые прилагательные
deleted: deleted_misc.txt // разные удаляемые слова
common : common_noun.txt // общеупотребительные существительные
class: lexclass_adj.txt // тезаурус прилагательных
class: lexclass_noun.txt // тезаурус существительных
control : controll1.txt // модели управления
```

Файлы-глоссарии: **linglexclass.txt,** **lingroles.txt,** **lingconnectors.txt**

Файлы-глоссарии позволяют задать списки обозначений, используемых для проверки словарной информации на отсутствие орфографических ошибок. При наличии в словарях неизвестных обозначений программа сборки сообщит об ошибках, описанных в разделе «Сборка словарей».

linglexclass.txt – содержит перечень наименований семантических категорий тезауруса и словаря моделей управления. Разделителями служат символы “;”, пробела и табуляции. Написание наименований чувствительно к регистру.

lingroles.txt – содержит перечень наименований семантических ролей словаря моделей управления. Разделителями служат символы “;”, пробела и табуляции. Написание наименований чувствительно к регистру.

lingconnectors.txt – содержит перечень предлогов и союзов, используемых в словаре моделей управления. Каждая строка может содержать только один предлог или союз. Их написание не чувствительно к регистру, расстановке пробельных символов и знаков препинания.

Во всех словарях знак “/” обозначает начало комментария, который продолжается до конца строки.

Настройка словаря моделей управления

В списке словарей (файл **lingdic.ini**) словари данного типа указываются с ключевым словом “control”.

Формат файла

Каждая строка файла задает модель управления для набора слов и имеет вид (в нотации БНФ):

```
<слово>(,<слово>)* <тип управления> (<коннектор>)? <падеж>? (CAT:
  (<CategoriesList>)+ )?
```

где

```
CategoriesList ::= (<категория>(;<категория>)*)+
```

Здесь символ “*” означает ноль или более повторений выражения в круглых скобках, “+” – одно или более повторений, а “?” – ноль или одно повторение.

Коннектор представляет собой предлог или союз, в том числе из нескольких слов, разделенных пробелами и знаками препинания.

Выражение **CategoriesList** определяет перечень семантических категорий, к которым должно относиться слово в грамматической форме, заданной моделью управления. В качестве категории может быть также указано любое слово русского языка. Списков категорий или отдельных слов может быть несколько, разделенных символом табуляции. В этом случае модели управления удовлетворяют лишь слова, относящиеся ко всем категориям, приведенным в любом из данных перечней. Если список категорий пуст, модели управления отвечает любое слово в заданной грамматической форме.

Для разделения элементов строки используется только символ табуляции.

Все слова должны быть указаны в нормальной форме. Управление прямыми и возвратными формами глаголов должно задаваться отдельно, при этом во втором случае – в возвратной форме инфинитива.

Все используемые предлоги и союзы должны быть указаны в файле-гlossарии **lingconnectors.txt**. Все используемые названия семантических категорий должны быть указаны в файле-гlossарии **lingroles.txt**. В противном случае приложение сборки словаря выдает сообщение об ошибке.

Замечание. При анализе семантические категории слов извлекаются из тезауруса-классификатора или модуля выделения объектов в тексте (см. «*RCO Pattern Extractor – руководство администратора*»). Если категория слова не определена, считается, что оно удовлетворяет всем ограничениям в моделях управления, кроме представленных конкретными словами.

Написание типов управления, падежей и названий семантических категорий чувствительно к регистру. Написание слов, предлогов и союзов нечувствительно к регистру, за исключением аббревиатур и имен собственных, которые должны писаться с большой буквы.

Ключевые слова

CAT – начало списка семантических ограничений.

noun, verb, inf, adj – тип управления (см. раздел «[Типы управления](#)»).

И, Р, Д, В, Т, П – обозначения соответствующих падежей (см. раздел «[Падежи](#)»).

Комментарии

Комментарий, продолжающийся до конца строки, начинается с метки “//”.

Пример файла словаря моделей управления

```
// подписал -> руководитель, ООО "Ромашка" <- подписало
подписать noun И субъект CAT: name;men      name;offic
// агитировать -> (с помощью) листовок
АГИТИРОВАТЬ,САГИТИРОВАТЬ noun с помощью Р способ
ГОТОВНОСТЬ inf // готовность -> исполнить
Казаться,показаться adj Т признак // казаться -> сильным
видеть,увидеть verb как // увидеть -> (как) произошло
```

Настройка тезауруса-классификатора

В списке словарей (файл **lingdic.ini**) словари данного типа указываются с ключевым словом “*class*”.

Формат файла

Каждая строка файла имеет вид (в нотации БНФ):

```
<часть речи> <слово>(<синоним>)* (<базовый термин>)?
(CAT: CategoriesList)?
```

где

```
CategoriesList ::= <категория>(<категория>)*
```

Здесь символ “*” означает ноль или более повторений выражения в круглых скобках, “+” – одно или более повторений, а “?” – ноль или одно повторение.

Все слова должны быть в нормальной форме, указанная часть речи – соответствовать части речи слова из морфологического словаря, синонимы – принадлежать к одной части речи. Используемые коды частей речи приведены в [Приложении 1](#). В качестве обобщающего слова (гиперонима) допустимо использование только существительных и эквивалентных им частей речи, имеющих коды **Noun**, **Name**, **GeoName**, **Abbr**, **Appellation**.

При анализе текста все слова синонимического ряда вначале приводятся к главному синониму – слову, которое указано первым в строке синонимов. Далее в некоторых синтаксических конструкциях главный синоним может быть приведен к базовому термину.

Замечание. Помимо тезауруса-классификатора, замена синонимов может также производиться в модуле выделения объектов в тексте (см. документацию «*RCO Pattern Extractor – руководство администратора*»).

Названия используемых семантических категорий необходимо указать в файле-глоссарии **linglexclass.txt**, иначе приложение сборки словаря сообщит об ошибке.

Написание кодов частей речи и названий семантических категорий чувствительно к регистру. Написание слов нечувствительно к регистру, кроме аббревиатур и имен собственных, пишущихся с большой буквы.

Замечание. Помимо тезауруса-классификатора, при анализе текста семантические категории некоторых слов могут проставляться в модуле выделения объектов в тексте (см. «*RCO Pattern Extractor – руководство администратора*»). В этом случае категория из тезауруса игнорируется.

Ключевые слова

CAT – начало списка категорий.

Комментарии

Комментарий, продолжающийся до конца строки, начинается с метки “//”.

Пример файла тезауруса-классификатора

```
Adjective выносливый, двужильный выносливость // нет категории Noun
воровство, кража CAT: f;act;pres // нет обобщающего
Verb воровать, красть, украсть воровство CAT: f;act;pres
Verb вкладывать, вложить, вложить вклад CAT: f;act;pres
Verb воспламенить воспламенение CAT: f;act;emot f;act;phys
Verb воспламенить CAT: f;act;emot f;act;phys
Noun воспламенение CAT: f;act;emot f;act;phys
Verb воспламенять, воспламенить воспламенение
```

Замечание. Допустимо указание одного слова в нескольких строках файла, что иллюстрирует приведенный пример. То есть можно в одной строке указать синонимы, в другой – базовый термин, а в третьей – категории. Общее требование, которое при этом не должно нарушаться, состоит в согласованности и однозначности информации, указанной в различных строках словаря, – слова, к которым приводятся другие слова, сами не должны приводиться к другим словам. Так, транзитивность вида «*украсть, красть*» и «*красть, воровать*», рефлексивность вида «*кража воровство*», «*воровство кража*» в тезаурусе не допускается! В случае подобных нарушений приложение сборки словаря выдает предупреждение.

Настройка словарей общеупотребительной лексики

Словари общеупотребительной лексики содержат удаляемые и общеупотребительные слова русского языка, специфика обработки которых описана в разделе «[Введение. Словари общеупотребительной лексики](#)».

В списке словарей (файл **lingdic.ini**) словари удаляемых слов указываются с ключевым словом “*deleted*”, а словари общеупотребительных слов – с ключевым словом “*common*”.

Формат записи словарей

Каждая строка файла удаляемых или общеупотребительных слов имеет вид:

```
<слово>      (SP: <часть речи>)?
```

Указание части речи не обязательно, но желательно, так как помогает разрешить омонимию в случае ее наличия (например, «*стать*» – нормальная форма как глагола, так и существительного).

Комментарии

Комментарий, продолжающийся до конца строки, начинается с метки “//”.

Пример файла

```
стать      SP: Verb    // удаляемый глагол
стать      SP: Noun    // общеупотребительное существительное
АНАЛОГИЧНЫЙ           // удаляемое слово
Четверть           // удаляемое слово
```

Сборка словарей – приложение LingDicCompiler

Сборки новой версии бинарного словаря **lingdct.dat**, который использует **RCO**, производится из консоли запуском приложения **LingDicCompiler.exe**, расположенного в базовой папке установки пакета **RCO Ling**.

Сообщения об ошибках и предупреждения в ходе сборки помещаются в файл **errors.txt**. Сообщения могут быть вызваны следующими причинами:

- невозможностью открыть один из файлов-гlossариев **linglexclass.txt**, **lingroles.txt**, **lingconnectors.txt** (указанный файл отсутствует в папке запуска **LingDicCompiler.exe**);
- невозможностью открыть файл, указанный в списке **lingdic.ini** (неверно задано имя файла или файл отсутствует);
- приведенная в словаре семантическая категория, семантическая роль или коннектор связи отсутствует в соответствующем файле-гlossарии **linglexclass.txt**, **lingroles.txt**, **lingconnectors.txt**;
- неверно указана часть речи, тип управления или падеж (список используемых кодов приведен в [Приложении 1](#));
- указанное слово отсутствует в словаре морфологического анализа, задано не в нормальной форме или указана неверная часть речи. Возможно, стоит поставить слово в нормальную форму или изменить часть речи либо слово, указанное в качестве обобщающего, не является существительным. Если же слово действительно отсутствует в морфологическом словаре, его необходимо добавить в **MorphDct.dat**, обратившись к документации «*RCO Morph – пакет настройки словаря морфологического анализа*», после чего собрать словари семантического анализа заново;

- слово имеет другой синоним, другой базовый термин, или базовый термин имеет другой синоним. Нарушены требования однозначности при задании отношений в тезаурусе (см. раздел [Тезаурус-классификатор](#)).

Причина прочих ошибок – нарушение формата записи файлов.

Приложение 1. Используемые обозначения

Ниже перечислены обозначения, используемые в словарях.

Коды частей речи

В таблице приведены допустимые коды частей речи, используемые в тезаурусе и словарях общеупотребительной лексики.

Код	Часть речи	Пример
<i>Unknown</i>	Неизвестна	-
<i>Introductory</i>	Вводное слово	скорее, однако
<i>Interjection</i>	Междометье	ах
<i>Predicative</i>	Предикатив	трудно, нельзя, был
<i>Preposition</i>	Предлог	для, посредством
<i>Conjunction</i>	Союз	что, иначе
<i>Particle</i>	Частица	же, уж
<i>Adverb</i>	Наречие	скорее, тепло
<i>Comparative</i>	Обособленная сравнительная степень	скорее
<i>Pronoun</i>	Местоимение	что, ты
<i>Numeric</i>	Числительное	несколько, двадцать, пятый
<i>Abbr</i>	Аббревиатура	МГУ, РФ
<i>Name</i>	Имя собственное	Вася, Иванов, Петрович
<i>GeoName</i>	Географическое название	Крым, Москва
<i>Verb</i>	Глагол	длиться, быть
<i>Adjective</i>	Прилагательное	быстрый, свой
<i>Noun</i>	Существительное	использование, уж
<i>Appellation</i>	Наименование	Газпром, Гарант-Парк

Типы управления

В таблице приведены допустимые коды типов управления, используемые в словаре моделей управления.

Код	Тип управления	Пример
<i>noun</i>	управление существительным (с предлогом или без него)	<i>арендует -> машину, аренда -> (у) автобазы, человеку <- нельзя</i>
<i>inf</i>	управление глаголом в инфинитиве	<i>учил -> стрелять, попытка -> найти, можно -> играть, готовый -> ударить</i>
<i>verb</i>	управление глаголом в личной форме в придаточном предложении (с союзом)	<i>слышал -> (что) произошло, увидел -> (как) случилось</i>
<i>adj</i>	управление прилагательным	<i>казаться -> веселым, была -> свежая</i>

Падежи

В словаре моделей управления допустимы следующие обозначения падежей:

И – именительный, *Р* – родительный, *Д* – дательный, *В* – винительный, *Т* – творительный, *П* – предложный.