



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](mailto:info@rco.ru)  
<http://www.rco.ru>

## **Руководство администратора RCO**

### **Настройка описаний объектов**

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

Обзор.....	4
Общие правила .....	4
Описание персоны.....	5
Фамилия.....	5
Имя.....	5
Отчество .....	5
Род.....	5
Синоним (множ.) .....	5
Контекстный синоним (множ.) .....	6
Референтный контекст (множ.) .....	6
Тип склонения.....	6
Описание организации.....	7
Полное название .....	7
Признак изменяемости.....	7
Род.....	7
Синоним (множ.) .....	7
Тип склонения.....	7

## Обзор

В этом руководстве содержатся основные сведения по настройке описаний именованных объектов (персон и организаций), используемых в программных продуктах **RCO**.

Наличие полного описания объекта в дополнение к общим лингвистическим правилам позволяет более точно идентифицировать в тексте все упоминания объекта, отождествляя различные способы его обозначения. Описания задаются в едином xml-формате и включаются в состав лингвистического обеспечения, используемого продуктами **RCO**, согласно соответствующему регламенту (см. документацию по конкретному продукту).

## Общие правила

Описание объекта включает в себя набор строковых атрибутов, значения которых задаются пользователем.

Все объекты имеют атрибут, называемый *идентификатор объекта*, который содержит наименование объекта в произвольной, удобной для пользователя форме. Значение этого идентификатора используется в качестве обозначения объекта при выдаче результатов анализа текста в пользовательском интерфейсе.

Состав прочих атрибутов зависит от типа объекта («персона», «организация») и перечисляется далее.

При задании строковых значений атрибутов следует неукоснительно соблюдать ряд общих правил, как то:

1. Текстовая строка (слово или словосочетание) должна стоять в нормальной форме, т.е. в той форме, в которой принято писать заголовки словарных статей, за исключением атрибутов-синонимов, о чем сказано ниже. При этом первое существительное ставится в форму именительного падежа (обычно в единственном числе), а формы прилагательных согласуются с существительными (*Союз производителей черных и цветных металлов, металлургический комбинат, «Юкос», Иванов, Михаил, президент*). Указание формы множественного числа автоматически означает, что формы единственного числа при поиске в тексте следует игнорировать, например: «*Мобильные телесистемы*».

2. Текстовая строка – слово или словосочетание – должно быть написано с учетом следующих требований к регистру символов:

- а) имена нарицательные пишутся строчными буквами, за исключением прилагательных в названиях организаций, например, *Московский государственный университет*. Написание с заглавной буквы первого символа слова/словосочетания автоматически означает, что соответствующая строка в тексте обязана начинаться с заглавной буквы.
- б) Имена собственные пишутся с заглавной буквы (*Василий, Иванов, «Газпром»*). При этом неизменяемые названия организаций следует писать целиком заглавными буквами (*МДМ, НОСТА*). Слово или словосочетание, написанное латиницей, всегда означает неизменяемое название (*Microsoft, TWG, Raiffeisen Zentralbank Osterreich AG*).

В качестве синонимов к объектам не разрешается использовать имена объектов другого класса, например фамилия *Ходорковский* не может использоваться в качестве синонима к компании «Юкос» и наоборот.

## Описание персоны

Описание объекта типа «персона» задается в xml-файле следующего формата:

```
<object id="ИдентификаторОбъекта" type="person">
<fields>
<field name="gender">Род</field>
<field name="last name" modify="Изменяемость">Фамилия</field>
<field name="first name" modify="Изменяемость">Имя</field>
<field name="middle name" modify="Изменяемость">Отчество</field>
</fields>
<desc>
<syn type="normal" case="Склонение">Синоним</syn>
<syn type="normal" case="Склонение">Синоним</syn>
...
<syn type="context" case="Склонение">КонтекстныйСиноним</syn>
<syn type="context" case="Склонение">КонтекстныйСиноним</syn>
...
<syn type="referent">РеферентныйКонтекст</syn>
<syn type="referent">РеферентныйКонтекст</syn>
...
</desc>
</object>
```

Описание объекта типа «персона» содержит атрибуты, перечисленные ниже. Любой из атрибутов, кроме идентификатора и рода, может отсутствовать. Некоторые атрибуты могут иметь много различных значений, что отмечено как *множ.*

### Фамилия

Одно слово в нормальной форме, написанное с заглавной буквы. Слово имеет [признак изменяемости](#).

### Имя

Одно слово в нормальной форме, написанное с заглавной буквы. Слово имеет [признак изменяемости](#).

### Отчество

Одно слово в нормальной форме, написанное с заглавной буквы. Слово имеет [признак изменяемости](#). Указывает, склоняется слово (имя, фамилия, отчество) или нет. Возможные значения: *yes, no*.

### Род

Род персоны. Возможные значения: *мужской, женский*.

### Синоним (множ.)

Возможное синонимичное обозначение объекта в тексте – слово или словосочетание, заданное в нормальной форме. Для персоны это обычно должность, прозвище. Например, синонимами к *Владимиру Путину* являются слова: *президент России, российский президент, российский лидер, кремлевская власть, Кремль*. При нахождении в тексте такого обозначения оно считается синонимом объекта, если в тексте нет информации о том, что это обозначение другого объекта. Так, *президент России* будет считаться обозначением *Владимира Путина*, если в тексте не сказано: *президент России Борис Ельцин, новый президент России* и т.п.

## Контекстный синоним (множ.)

Возможное синонимичное обозначение объекта в тексте – слово или словосочетание, заданное в нормальной форме. В отличие от обычного синонима, контекстный синоним считается обозначением соответствующего объекта лишь в том случае, если ранее в тексте явно упоминался сам объект (по ФИО или синониму). Например, для *Аллы Пугачевой* контекстными синонимами могут быть слова: *певица, примадонна, звезда эстрады, звезда российской эстрады*. Так же, как и обычные синонимы, контекстные синонимы проверяются на отсутствие противоречий в тексте: *звезда эстрады* будет считаться обозначением *Аллы Пугачевой*, если в тексте не сказано: *звезда эстрады София Ротару, известная эстрадная певица*.

## Референтный контекст (множ.)

Слова и словосочетания, заданные в нормальной форме, присутствие которых в тексте позволяет снять неоднозначность – распознать соответствующий объект в случае, если он обозначен только именем и отчеством, или же его наименование (ФИО, синоним) может относиться к другим объектам. Например, присутствие в тексте таких слов, как *президентская гонка, российский лидер* позволяет отождествить неизвестный объект, названный *Владимир Владимирович*, с *Владимиром Путиным*, если в тексте не сказано *Владимир Владимирович Маяковский* или нечто подобное. А в случае, если используются описания двух объектов – *Путина* и *Ельцина*, то присутствие этих слов позволяет отождествить неуказанного в тексте *российского президента* с *Путиным*, а присутствие слов *расстрел Белого дома* – с *Ельциным*. При задании референтных контекстов нежелательно использовать имена собственные, так как это может помешать нормальной обработке объектов, имеющих эти имена.

## Тип склонения

Определяет, каким образом строятся все грамматические формы, соответствующие заданному синониму. Возможны следующие значения:

- «Нормальная форма» или отсутствие значения – в этом случае грамматические формы синонима во всех падежах будут построены программой автоматически по заданной нормальной форме, на основании словаря и правил грамматики русского языка. При этом предполагается, что в составе словосочетаний склоняется только первое имя существительное вместе с предшествующими ему прилагательными, а следующие за ним слова должны стоять в той форме, в которой указаны;
- «Неизменяемое» – грамматические формы синонима во всех падежах совпадают с указанной формой;
- «Именительный», «Родительный», ... или «Предложный» – указанная форма синонима соответствует заданному падежу.

Возможность явного указания склонения синонима позволяет точно распознавать и правильно связывать с другими словами сколь угодно сложные наименования персоны, в том числе не укладывающиеся в структуру ФИО, например *Патриарх Московский и всея Руси Алексей II, Гассан Абдурахман ибн Хоттаб IV*. В этом случае в описании объекта необходимо оставить пустыми значения атрибутов *Фамилия, Имя, Отчество*, добавив в синонимы все варианты написания наименования с указанием каждого из шести русских падежей.

## Описание организации

Описание объекта типа «*организация*» задается в xml-файле следующего формата:

```
<object id="ИдентификаторОбъекта" type="organization">
<fields>
<field name="gender">Род</field>
<field name="full name" modify="Изменяемость">ПолноеНазвание</field>
</fields>
<desc>
<syn type="normal" case="Склонение">Синоним</syn>
<syn type="normal" case="Склонение">Синоним</syn>
<...>
</desc>
</object>
```

Описание объекта типа «*организация*» содержит атрибуты, перечисленные ниже. Любой из атрибутов, кроме идентификатора, рода и полного названия, может отсутствовать. Некоторые атрибуты могут иметь много различных значений, что отмечено как *множ.*

### Полное название

Полное название организации («*Челябинский металлургический комбинат*», компания «*Мобильные телесистемы*», нефтяная компания «*Лукойл*», «*Национальный резервный банк*», холдинговая компания «*Интеррос*», министерство транспорта РФ, корпорация *Trans World Group*). Как видно из приведенных примеров, желательно отразить в полном названии род деятельности организации, используя слова типа «*завод*», «*банк*», «*компания*», что будет задействовано при отождествлении с именем собственным косвенных обозначений организации в тексте. Нежелательно использовать в названии обозначения организационно-правовой формы: ООО, открытое акционерное общество и т.п.

### Признак изменяемости

Указывает, склоняется слово или нет. Относится только к тому слову в названии, которое представляет имя собственное (*МТС* – неизменяемое, «*Интеррос*» – изменяемое). Возможные значения: *yes, no*.

### Род

Грамматический род относится только к тому слову в названии, которое представляет имя собственное («*Татнефть*» – женского рода, «*Интеррос*» – мужского рода). Возможны значения: *мужской, женский* или *средний*.

### Синоним (множ.)

Возможное синонимичное обозначение объекта в тексте – слово или словосочетание, заданное в нормальной форме. Синоним должен иметь соответствующий объекту лексико-семантический разряд. Например: *МДМ, группа МДМ, группа МДМ, группа «Московский деловой мир», «Московский деловой мир», МДМ-банк, филиал МДМ-банка*.

### Тип склонения

Определяет, каким образом строятся все грамматические формы, соответствующие заданному синониму. Возможны следующие значения:

- «Нормальная форма» или отсутствие значения – в этом случае грамматические формы синонима во всех падежах будут построены программой автоматически по заданной нормальной форме, на основании словаря и правил грамматики русского языка. При этом предполагается, что в составе словосочетаний склоняется только первое имя существительное вместе с предшествующими ему прилагательными, а следующие за ним слова должны стоять в той форме, в которой указаны;
- «Неизменяемое» – грамматические формы синонима во всех падежах совпадают с указанной формой;
- «Именительный», «Родительный», ... или «Предложный» – указанная форма синонима соответствует заданному падежу.

Возможность явного указания склонения синонима позволяет точно распознавать и правильно связывать с другими словами в тексте сколь угодно сложные наименования организаций, включающие в себя слова любых частей речи и знаки препинания («*Идущие вместе*», «*Отечество – вся Россия*»).