

Объектная модель многофункциональных словарей

Докладчик: Носков А. А.

Группа: 525

Научный руководитель: Большакова Е. И.

Рассматриваемая работа

«Объектная модель многофункциональных словарей, основанная на синтезе лингвистических единиц»

Ивличева О. О., Епифанов М.Е., Лахути Д.Г.

Попытка выработать универсальный метод организации данных для электронных словарей

Лингвистические единицы

- Морфема, лексема, словоформа...
- Простая/составная: морфема/словоформа
- Многоуровневая иерархия
 - Синтаксические конструкции образованы из словоформ, словоформы из основы и флексий
- Составная л.е. - результат некоторой операции над единицами нижнего уровня
 - Словоформа может быть получена как конкатенация ее составляющих

Свойства лингвистических единиц

- С единицами ассоциированы некоторые свойства
- Внутренние/наследуемые (для составных частей)
 - Словосочетание «большой корабль» наследует свойства рода, одушевленности и т.п. от «корабль»
 - Можно считать, что словоформа наследует свой падеж от окончания
- Со значением некоторых свойств связано «поведение», в частности, правила построения новых единиц
 - Род, число определяют согласование

Текст-объект

- В словаре конкретные лингвистические единицы представляются в виде текст-объектов
- Основы: «вершин», «дорог»
- Окончания: «а», «и», «ы»...
- **Текст-объект** — цепочка символов + конечное множество свойств

Свойства текст-объекта

- **Свойство** — тройка $p = \langle d, n, v \rangle$, где
 - d — тип свойства
 - n — имя свойства
 - v — значение свойства
- У одного текст-объекта не может быть свойств с одинаковым именем
- Примеры свойств
 - Падеж, число, одушевленность и прочие грамматические признаки
 - Семантическое значение суффикса

Аддитивные и внутренние свойства

- Свойства делятся на *аддитивные* и *внутренние*
 - **Аддитивные** — свойства, которые наследуются более сложными конструкциями
 - Род, число, одушевленность
 - **Внутренние** — свойства, которые не наследуются
 - Тип единицы
 - Часть речи
- Множества имен аддитивных и внутренних свойств не пересекаются
- Текст-объект - тройка $\langle t, AData, IData \rangle$ (строка, аддитивные свойства, внутренние свойства)

Соединение текст-объектов

- Используется для образования составных текст-объектов из более простых
- Текст-объекты *соединимы*, если все их аддитивные свойства могут быть успешно соединены
- <«вершин», { одуш:неод } , ∅> соединима с <«ы», { одуш:неод, число:ед, пад:вин } , ∅> но не соединима с <«», { одуш:од, число:ед, пад:вин } , ∅>

Соединение свойств

- Для каждого типа свойства определяется специальный оператор соединения свойств простых текст-объектов (пары объектов) в свойства составного текст-объекта
- Тип «согласуемое свойство» переносит в новый текст-объект свойства, только если e_1 и e_2 не содержат одноименных свойств с различными значениями

R-объекты

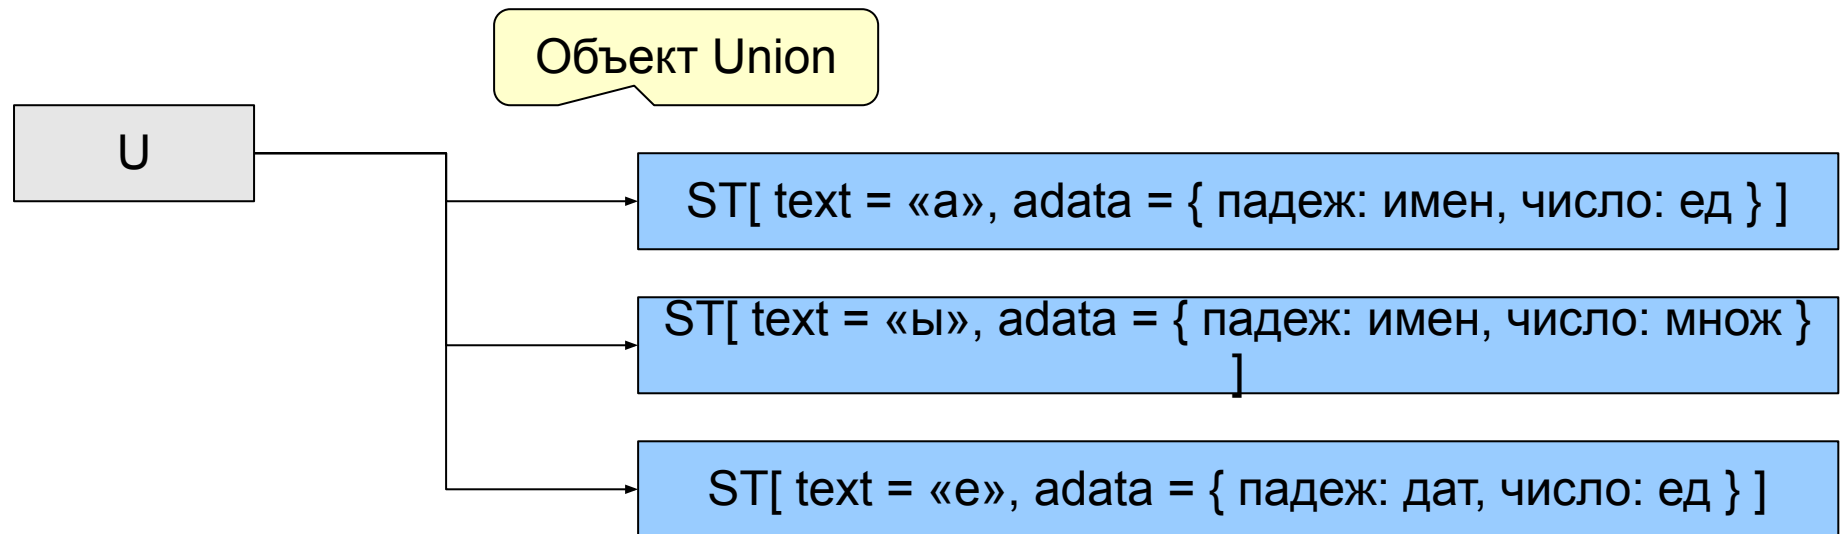
- R-объекты — собственно элементы структуры словаря.
- Могут быть четырех типов: SimpleText, Property, Union, Join
- Каждый R-объект e описывает какое-то множество текст-объектов
- Есть R-объекты, представляющие
 - Конкретные основы и флексии
 - Множества возможных основ, флексий
 - Множества допустимых словоформ
 - Множества допустимых словосочетаний

R-объекты: SimpleText

- `ST [text, adata, idata]` — R-объект, соответствующий одному текст-объекту
- Ими представляются основы и флексии
 - `ST [«вершин», {одуш:неодуш}, ∅]`
 - `ST [«а», {род:жен, числ:ед, пад:им}, ∅]`
 - `ST [«ы», {одуш:неодуш, числ:мн, пад:вин}, ∅]`
 - `ST [«», {одуш:одуш, числ:мн, пад:вин}, ∅]`
- Property эквивалентен SimpleText без поля text


R-объекты: Union

- Union — составной R-объект, который используется для объединения множеств, описываемых дочерними R-объектами
- Например, объект, объединяющий окончания в множество (таблицу флексий)



R-объекты: Join

- Для представления множеств составных единиц используется объект Join
- Join представляет множество соединений всех пар дочерних объектов
- Им представляются множества словоформ, словосочетаний

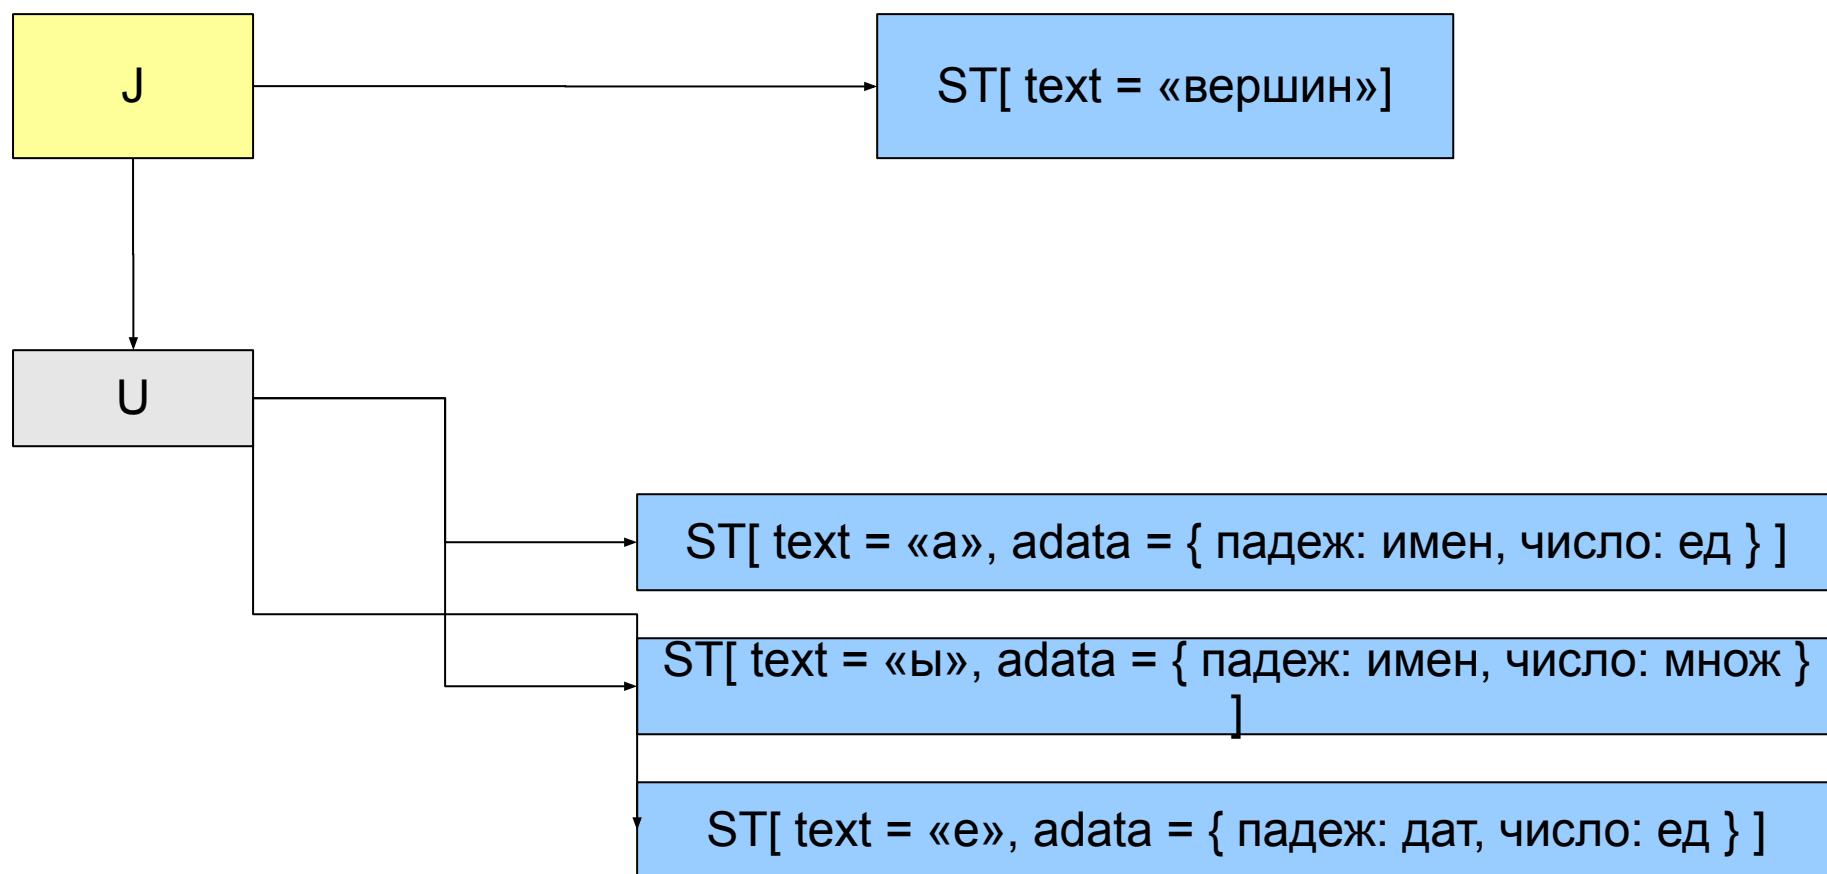


Построение словаря из R-объектов

- R-объекты организованы в иерархию
- Листьями в иерархии являются минимальные единицы: морфы, представленные SimpleText
- Составными элементами являются Union и Join, ссылающиеся на другие R-объекты
- При применении Join к основе и множеству Union окончаний, основа «склеивается» с каждым окончанием

Пример фрагмента словаря

Структура, описывающая слова «вершина», «вершины» и «вершине»

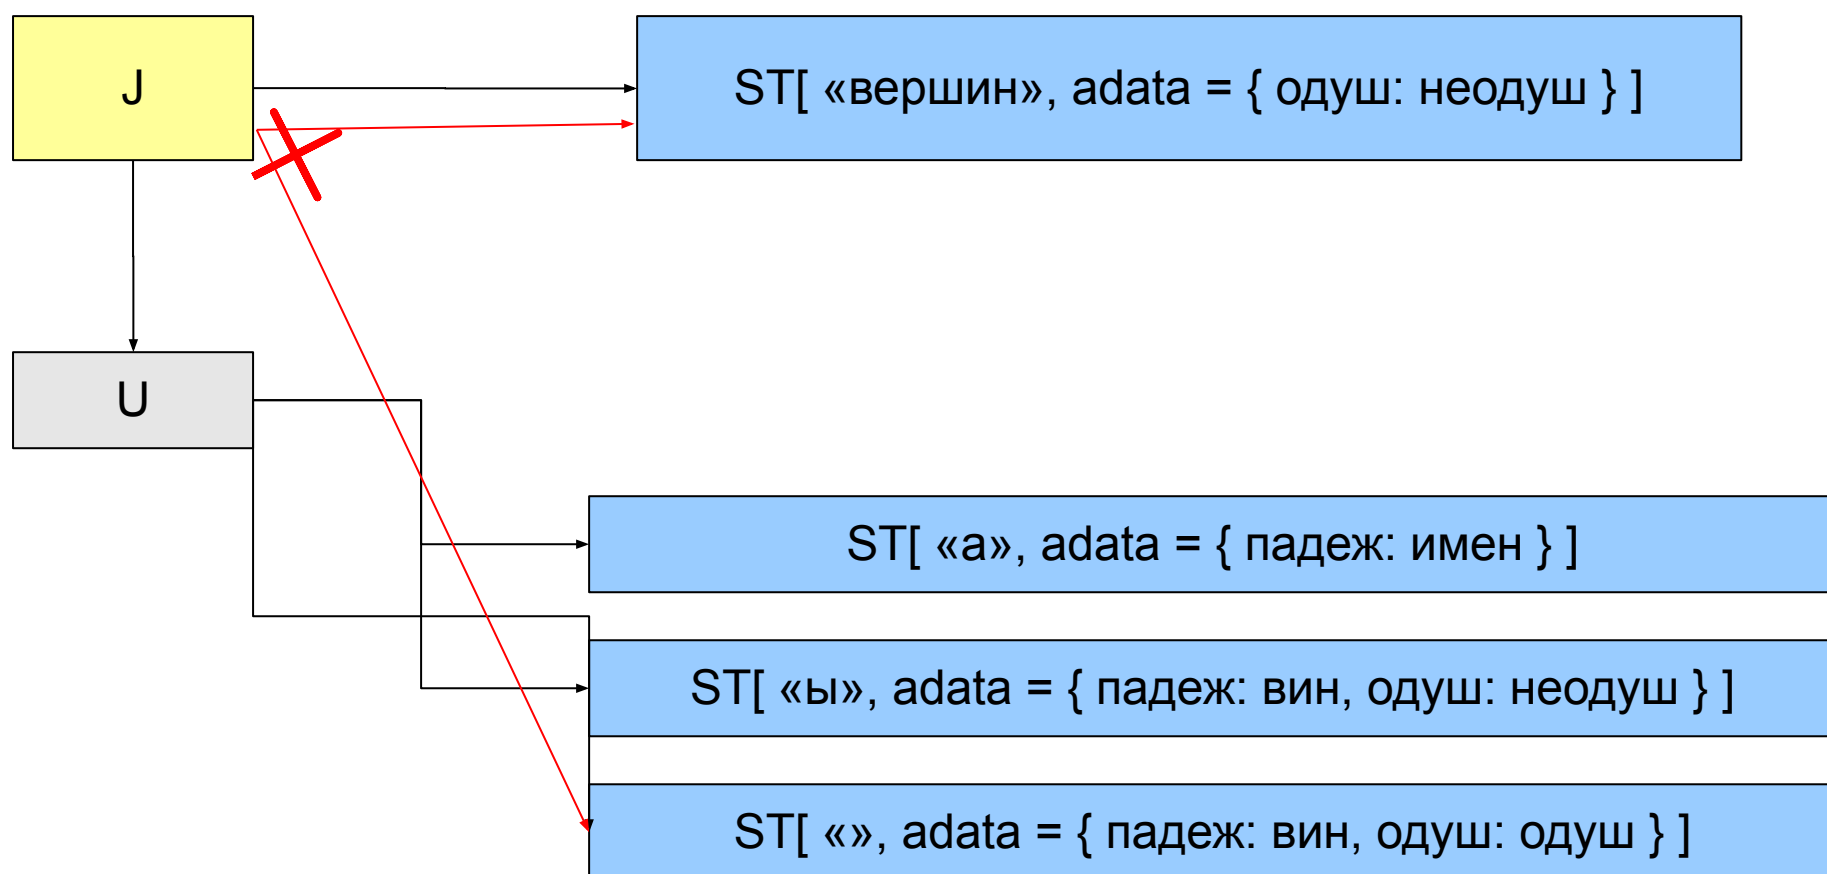


Недопустимые единицы


- Соединение может отвергать некоторые единицы, получаемые в результате синтеза как неправильные.
- Такие единицы состоят из несоединяемых объектов и не входят в результирующее множество.
- Простейший пример: конфликт значений свойств.

Пример недопустимых единиц

Конфликт свойства одушевленности, «вершин» - недопустимая форма!



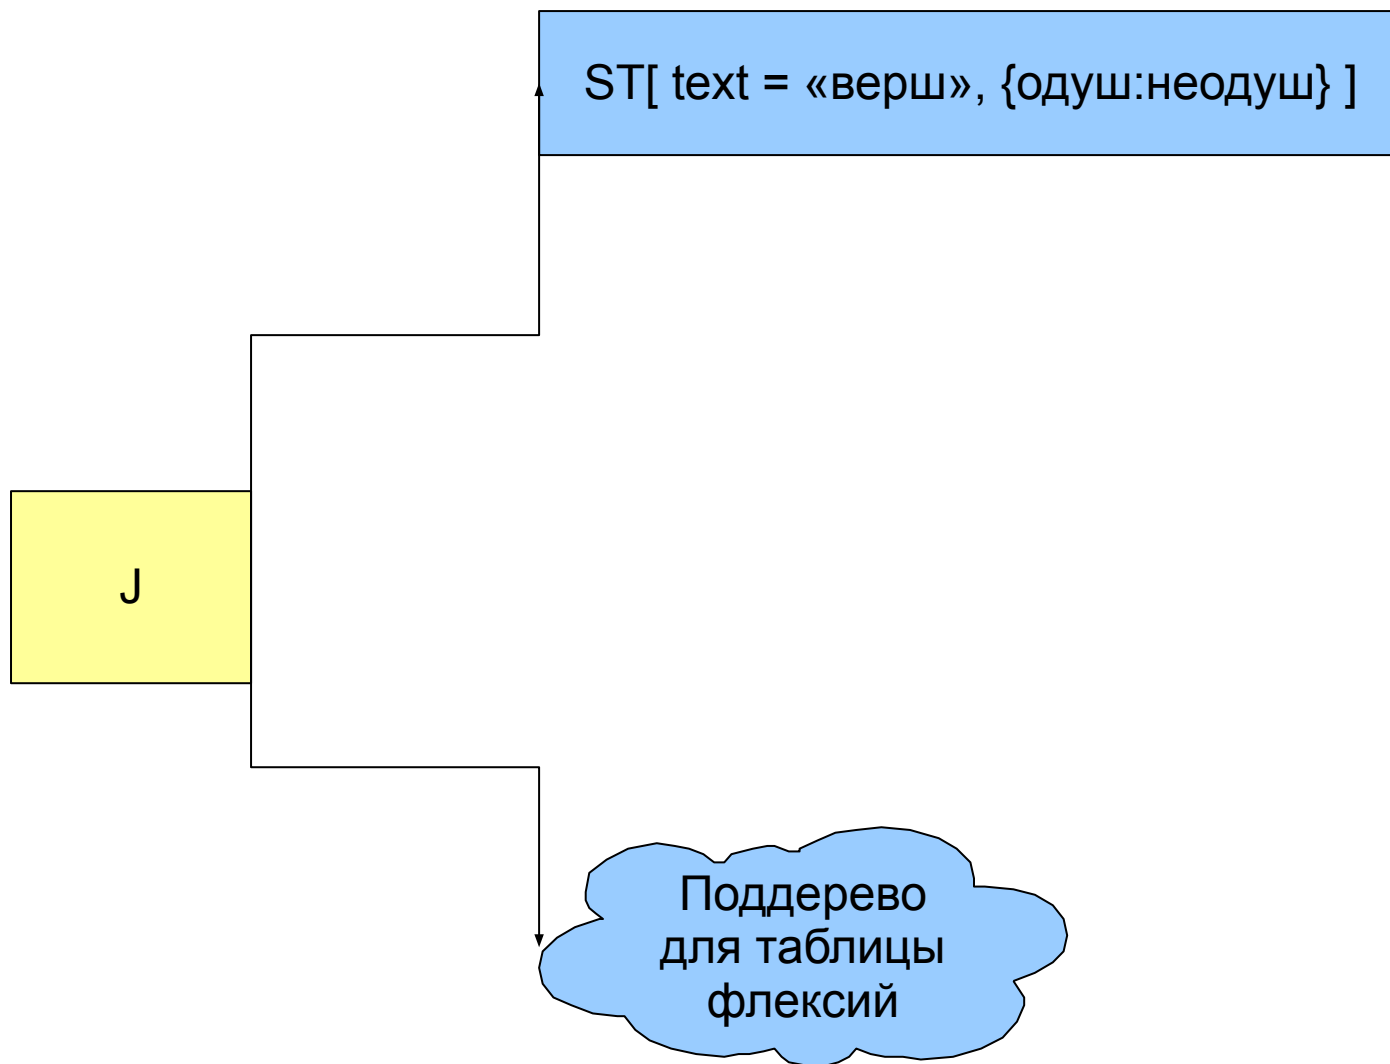
Представление словосочетаний




Расширяемость словаря

- Предложенный подход позволяет легко расширять словарь
 - «В ширину» - добавление новых данных в существующей схеме. **Добавление новых основ и флексий.**
 - «В глубину» - добавление качественно новой информации. **Добавление семантической информации.**

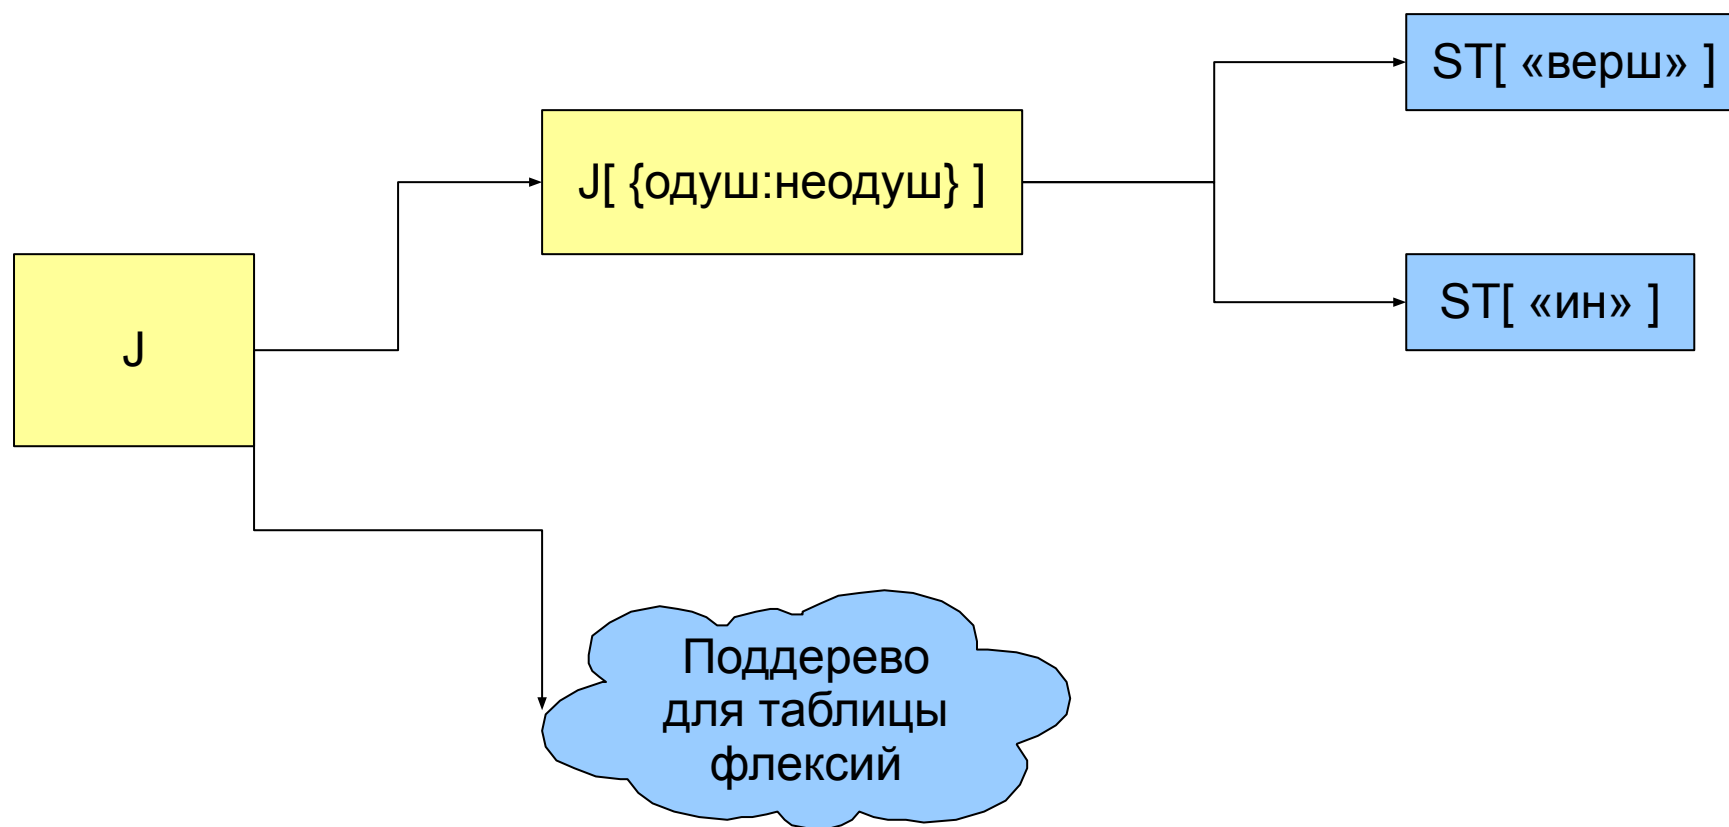
Расширяемость словаря



Расширяемость словаря




Расширяемость словаря

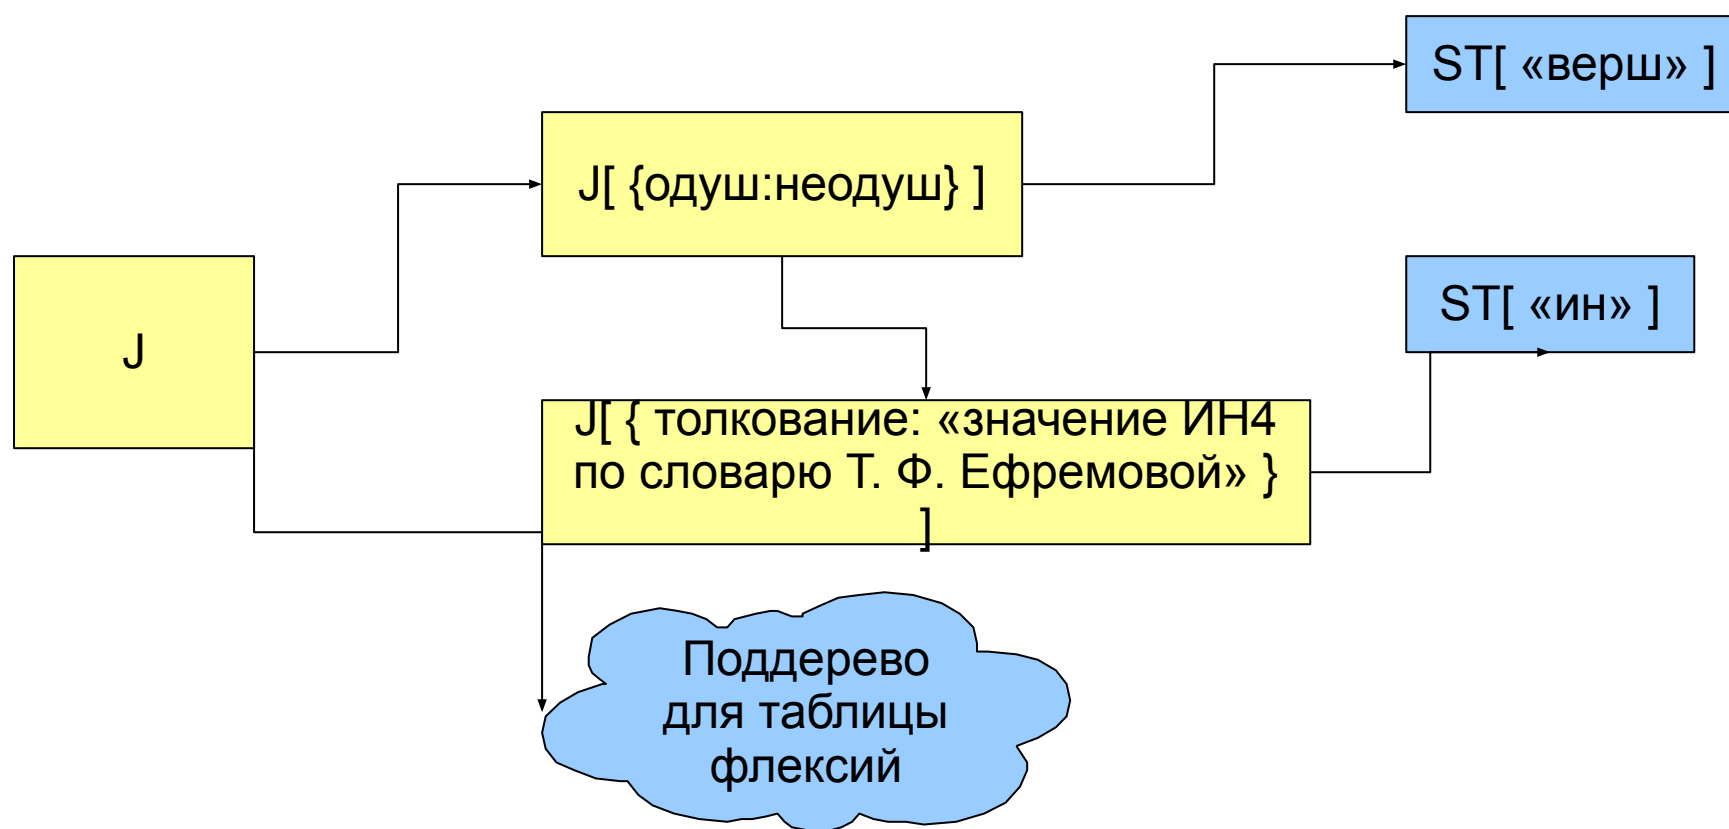


Расширяемость словаря

Добавляем семантическую информацию для суффикса



Расширяемость словаря



Реализация словаря

- Модель реализована на основе некоторой объектной библиотеки
- Каждый R-объект является объектом в смысле программном смысле, он инкапсулирует:
 - Свойства R-объектов
 - Методы запроса множества текст-объектов, возможно, с заданными ограничениями

Плюсы и минусы подхода

- Достаточно простой и мощный подход
- Унифицированное представление для различных задач
- Расширяемость «в ширину» и «в глубину»
- Возможность использования как модели для анализа
- Высокая вычислительная сложность при запросе элементов узла
- Кое-где модель неоправданно усложнена
- Опасность роста сложности модели при росте ее объема

