Дипломная работа

ПРОГРАММНЫЕ СРЕДСТВА ВЫЯВЛЕНИЯ ТЕРМИНОЛОГИЧЕСКИХ ВАРИАНТОВ В ТЕКСТАХ

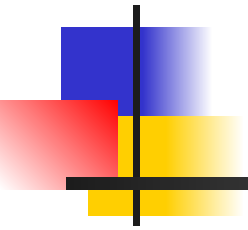

Антонов Вадим Юрьевич

Научный руководитель:
Ефремова Наталья Эрнестовна

ТЕРМИНЫ И ИХ ВАРИАНТЫ

- *Термины* – слова и словосочетания, называющие понятия предметной области
  - *рентгеновское излучение*
- Употребление терминов в текстах –> *терминологические варианты*
  - *излучение, рентгеновские лучи*
- Выявление терминологических вариантов важно учитывать при построении тезаурусов, онтологий, предметных указателей, классификации текстов

КЛАССИФИКАЦИЯ ВАРИАНТОВ

Классификация терминологических вариантов для научно-технических текстов:

- **графические** – *компьютер/Компьютер*
- **флективные** – *данные/данных*
- **орфографические** – *браузер/броузер*
- **морфемные** – *выполнение/исполнение*
- **сокращения** – *высшее учебное заведение/ВУЗ*
- **синонимы** – *абсорбция/поглощение*
- **лексико-синтаксические** – *центральный процессор/процессор, текстовая коллекция/коллекция текстов*

ПОСТАНОВКА ЗАДАЧИ

- Изучить классификацию терминологических вариантов и подходы к их выявлению
- На базе классификации разработать методы выявления терминологических вариантов в научно-технических текстах на русском языке
- На их основе реализовать программные средства
- Провести тестирование разработанных методов

ПОДХОДЫ К ВЫЯВЛЕНИЮ

- Символьный (статистический) подход
  - Термин и его варианты – символы
  - Вычисляется функция близости для термина и его варианта, для выбора порогового значения используется статистика
  - Не требуется лингвистическая информация и словари
  - Используется для орфографических и флективных вариантов
- Лингвистический подход
  - Термин и его варианты – словосочетания
  - Анализируется синтаксическая структура словосочетания, применяются правила образования вариантов и эвристики
  - Используется для лексико-синтаксических вариантов
  - Применён для английского и французского языков, для русского языка не изучен

ПРЕДЛАГАЕМОЕ РЕШЕНИЕ

Для каждого типа терминологических вариантов используется свой метод, основанный на одном из подходов

Тип варианта	Метод выявления
Графические	приведение символов к одному регистру
Флективные	морфологический анализ
Орфографические	расстояние Левенштейна
Морфемные	словарь морфемного состава
Сокращения	эвристики для сокращений по первым буквам
Синонимы	словарь синонимов
Лексико-синтаксические	**формальные правила образования вариантов**

ЛЕКСИКО-СИНТАКСИЧЕСКИЕ ВАРИАНТЫ: ФОРМАЛИЗАЦИЯ

- Информация о лексико-синтаксических вариантах формализована в виде правил их образования
- Для формализации выбран язык LSPL и его библиотека:
  - позволяет описывать конструкции естественного языка в виде **лексико-синтаксических шаблонов**
  - предусмотрена возможность обработки информации, полученной в результате наложения LSPL-шаблона
- Правило образования – лексико-синтаксический шаблон вида:

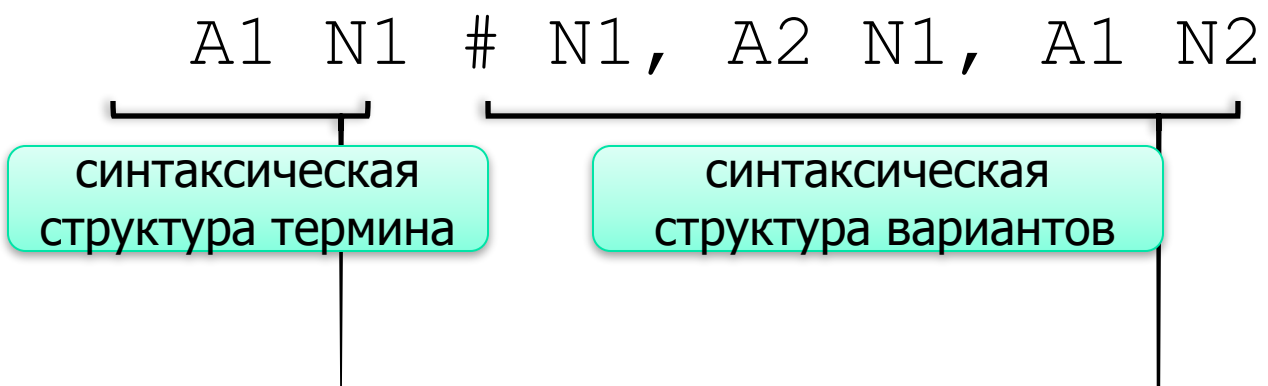

ЛЕКСИКО-СИНТАКСИЧЕСКИЕ ВАРИАНТЫ: ВЫЯВЛЕНИЕ

Основано на

автоматической конкретизации шаблона правила

согласование — словарь синонимов

```
A1 N1 <A1=N1> # A1 N2 <Syn(N1,N2),A1=N2>
```

рентгеновские лучи # *рентгеновское излучение*

термин — терминологический вариант

1 . Распознавание термина заданной структуры

   A1 => *рентгеновские*, N1 => *лучи*

2. Нормализация слов термина

   рентгеновские => *рентгеновский*, *лучи* => *луч*

3. Построение шаблона возможного варианта

   A1<рентгеновский> N2 <Syn(“луч”,N2),A1=N2>

4. Поиск варианта в тексте по конкретизированному шаблону

ОБЩАЯ ПРОЦЕДУРА ВЫЯВЛЕНИЯ

Исходная информация:

- Список терминов L_1
- Список кандидатов в терминологические варианты L_2

Алгоритм:

1. Для каждого $T_i \in L_1$ рассматриваем все $V_j \in L_2$
2. Для пары T_i и V_j проверяем, являются ли они вариантами, путём применения методов в определённом порядке

Результаты работы:

- Для каждого термина из L_1 – список терминологических вариантов из L_2

Порядок распознавания типа варианта
Графический
Флективный
Синонимы
Морфемный
Лексико-синтаксический
Сокращений
Орфографический

ПРОГРАММНЫЕ СРЕДСТВА: АРХИТЕКТУРА

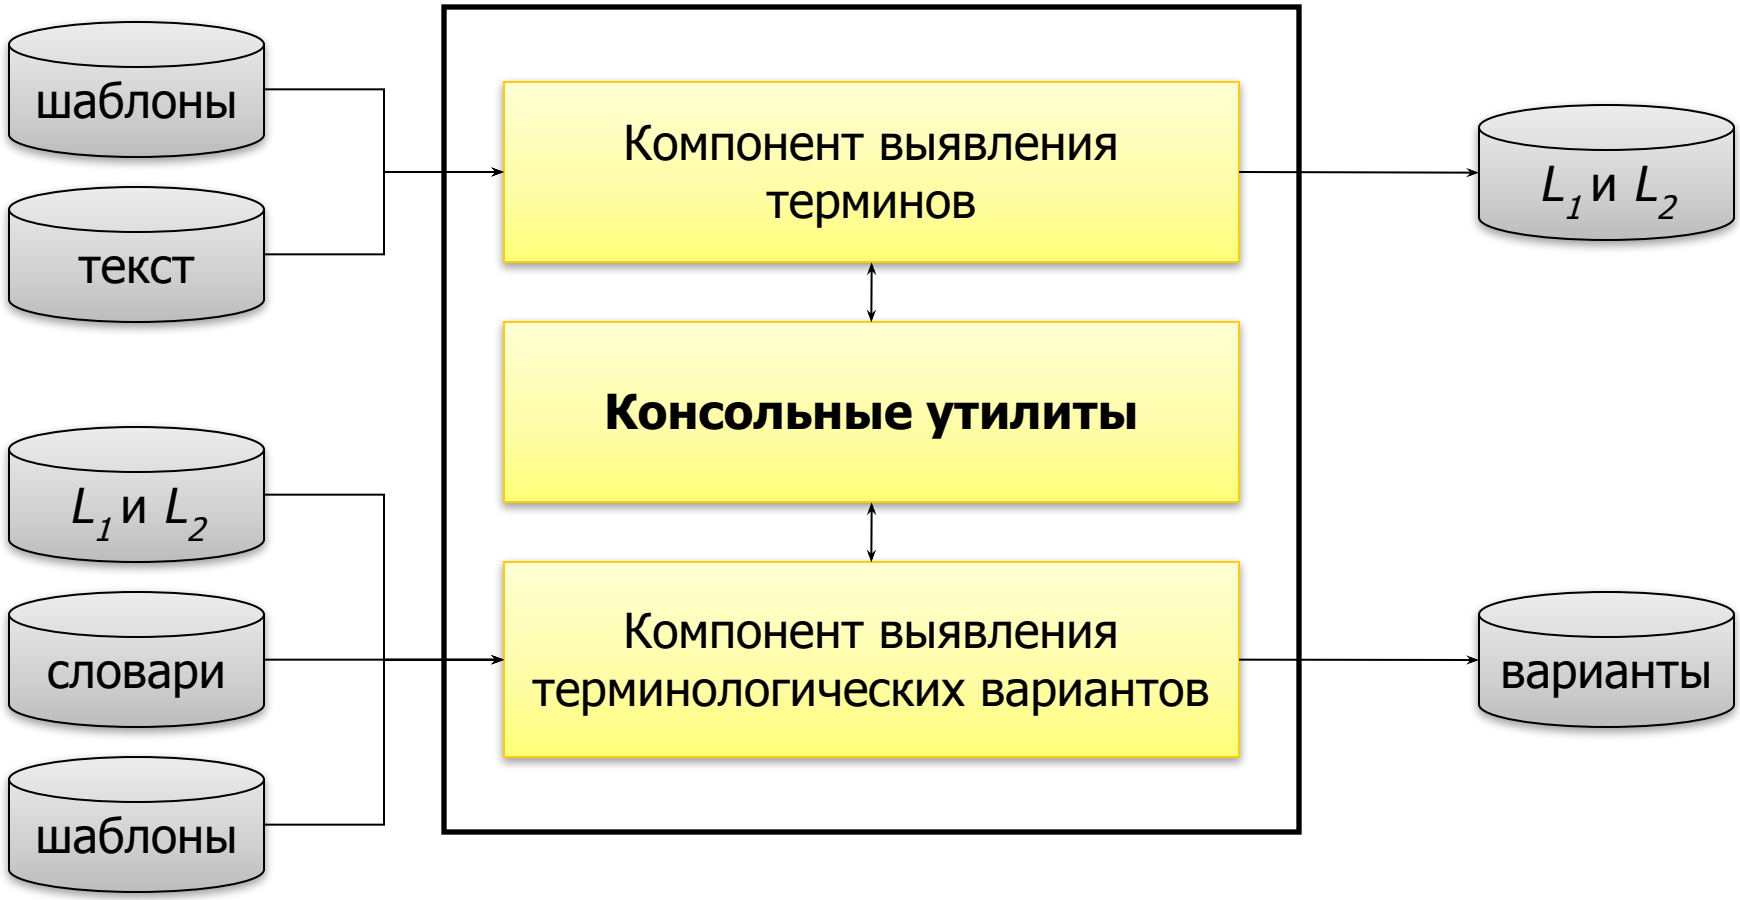

РЕАЛИЗАЦИЯ И ТЕСТИРОВАНИЕ МЕТОДОВ

- Для реализации использован язык C++
- Библиотеки: LSPL, AOT, boost, STL
- Система контроля версий: git
- **Тестирование** на научно-технических текстах из областей физики и информатики объемом более 500кб
- Полнота выявления вариантов: 91%
  Точность выявления вариантов: 86%
  - Выявлено употреблений терминов без учета терминологических вариантов: 13668
  - Выявлено употреблений терминов с учетом терминологических вариантов: 25178
  - Процент прироста употреблений терминов: 84%

РЕЗУЛЬТАТЫ РАБОТЫ

- Проанализированы современные подходы к выявлению терминологических вариантов, изучена классификация вариантов, типичных для русскоязычных научно-технических текстов
- Разработаны методы выявления терминологических вариантов в соответствии с классификацией
- Библиотека языка LSPL расширена для формирования конкретизированных шаблонов
- Методы выявления реализованы в виде программных средств
- Тестирование показало состоятельность предложенных методов выявления

Результаты работы были представлены

(с публикацией) на:

- Международной научной конференции студентов, аспирантов и молодых ученых «Ломоносов 2010»
- Международной конференции по компьютерной лингвистике и интеллектуальным технологиям «Диалог 2010»

СПАСИБО ЗА ВНИМАНИЕ!

Расстояние Левенштейна

- Минимальное количество операций вставки, удаления и замены, необходимых для перевода одной строки в другую

=	=	ЗАМ	=	=	=	=
Б	Р	А	У	З	Е	Р
Б	Р	О	У	З	Е	Р

=	=	=	=	ЗАМ	ВСТ
М	А	С	С	А	
М	А	С	С	О	Й