Синтаксический анализ для «встроенных» языков

Андрей Бреслав
Соавторы: A. Annamaa, V. Vene
(University of Tartu, Estonia)

STACC Software Technology and Applications Competence Center

Немного о предмете

```
SELECT id, date, title
     FROM Orders
     WHERE (user_id=239) AND (completed=FALSE)
     ORDER BY date ASC
```

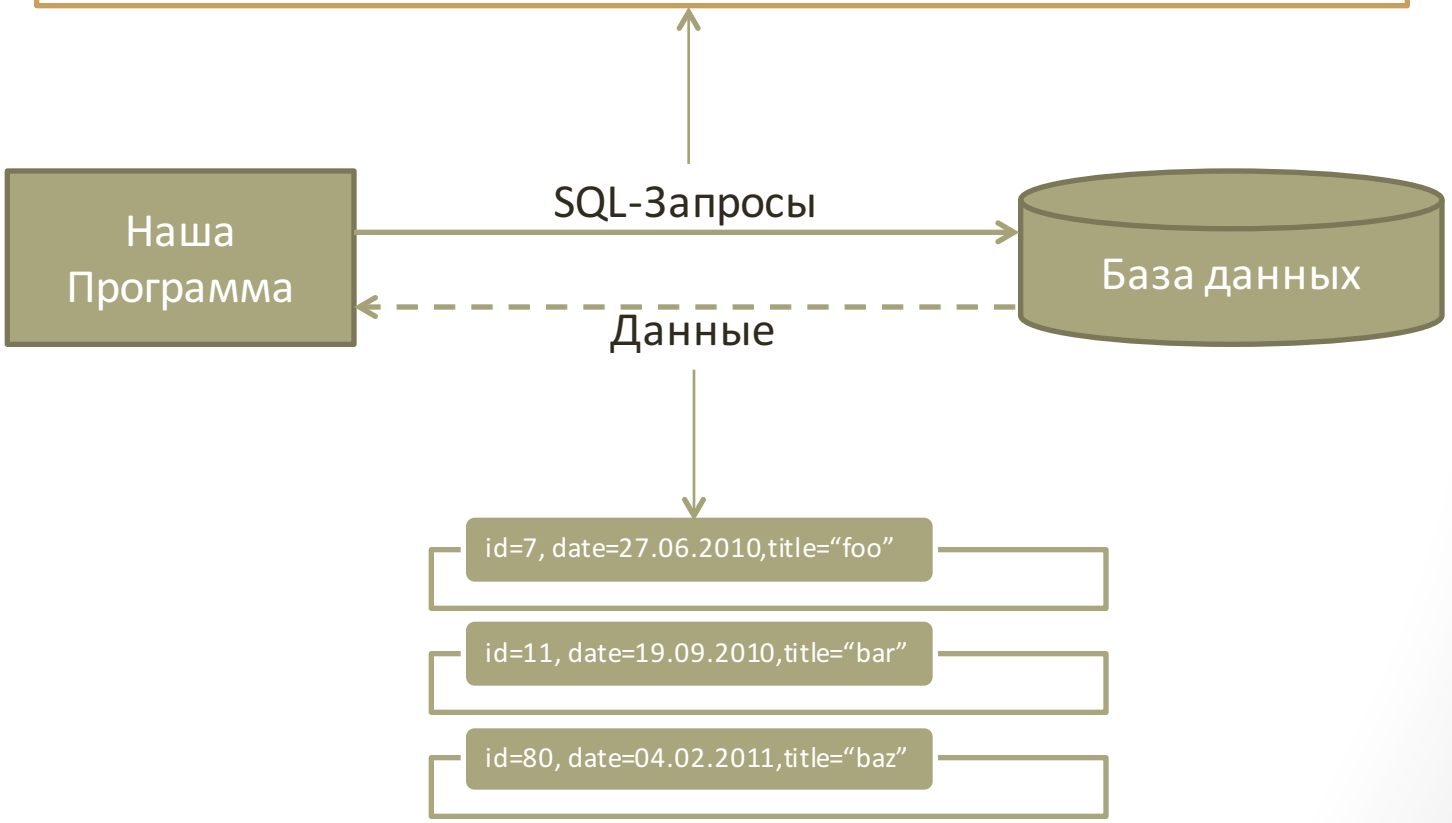

Как работает «Наша программа»


```
public PreparedStatement selectOrders(
                    int userId, boolean completedOnly,
                    boolean ascOrder) {
  String sql = "SELECT id, date, title," +
                    "FROM Orders" +
                    "WHERE (user_id=" + userId;
  if (completedOnly)
    sql += "AND (completed=FALSE)";
  sql += "ORDER BY date";
  sql += (ascOrder) ? "ASC" : "DESC";

  return ConnectionProvider.conn.prepareStatement(sql);
}
```

Кто заметил ошибки?


```
public PreparedStatement selectOrders(
                    int userId, boolean completedOnly,
                    boolean ascOrder) {
  String sql = "SELECT id, date, title, " +
               "FROM Orders" +
               "WHERE (user_id=" + userId;
  if (completedOnly)
    sql += "AND (completed=FALSE)";
  sql += "ORDER BY date";
  sql += (ascOrder) ? "ASC" : "DESC";

  return ConnectionProvider.conn.prepareStatement(sql);
}
```

Постановка задачи

- **Статически** обнаруживать
  синтаксические **ошибки**
  в SQL-запросах **внутри Java-строк**
  и сообщать о них пользователю,
  не запуская его программу

Что кроме SQL?

<?xml?>

URI:
git+ssh://foo.bar.com:foo.git

String.format(“Foo %s, %d bar!”, s, x);

Общая схема решения

Какие строковые выражения нужно проверить?

- `prepareStatement(`**`sql`**`)`
- `prepareCall(`**`sql`**`)`
- `executeQuery(`**`sql`**`)`
- `executeUpdate(`**`sql`**`)`

Каковы возможные значения данного выражения?

- Задача **алгоритмически неразрешима** в общем случае
- Как представить результат?
  - Множества бывают **бесконечными**

Удовлетворяют ли эти значения требованиям синтаксиса встроенного языка?

- **CF** $\subseteq$ **CF** – неразрешима
- **REG** $\subseteq$ **CF** – неразрешима
- **REG** $\subseteq$ **REG** – разрешима
  - но SQL – не регулярный

Общая схема решения

Какие строковые выражения нужно проверить?

- `prepareStatement(`**`sql`**`)`
- `prepareCall(`**`sql`**`)`
- `executeQuery(`**`sql`**`)`
- `executeUpdate(`**`sql`**`)`

Каковы возможные значения данного выражения?

- **Аппроксимация**:
  Построим регулярное множество, содержащее все возможные значения выражения

Удовлетворяют ли эти значения требованиям синтаксиса встроенного языка?

- **Аппроксимация:**
  Найдем регулярный язык, содержащийся в SQL, и будем проверять включение вида **REG** $\subseteq$ **REG** – разрешимая задача

Abstract Strings

```
String sql = "SELECT id";
if (needNames)
  sql += ", name";
sql += "FROM People WHERE age <= " + maxAge;
if (minAge >= 0)
  sql += "AND age >= " + minAge;

connection.prepareStatement(sql);
```

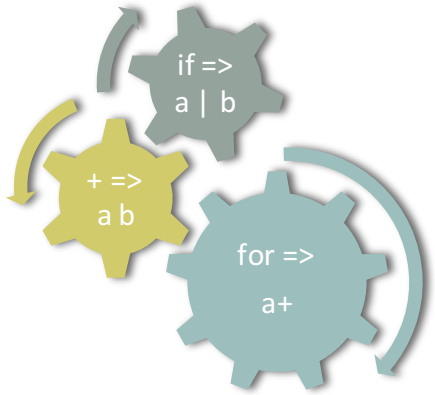

Где аппроксимация?

Сокращение:
AS? := (AS | "")

```
"SELECT_id" ",_name"? "FROM_People_WHERE_age_<=_"
                                    age ("AND_age_>=_" minAge)?
```

Время работы

Проект	Размер LOC	# Выражений		Время (сек)			Память
		всего	ошибок	общее	**AStrings**	**кэш**	
Plazma	48’520	94	4	6	**3.8**	**0.4**	65
Compiere	319’570	1343	12	138	**120**	**0.5**	445

Abstract Parsing

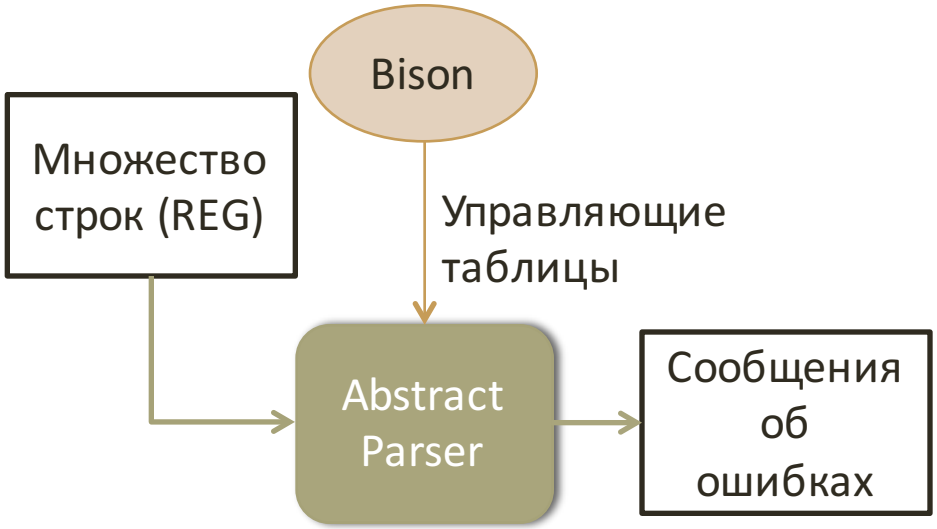

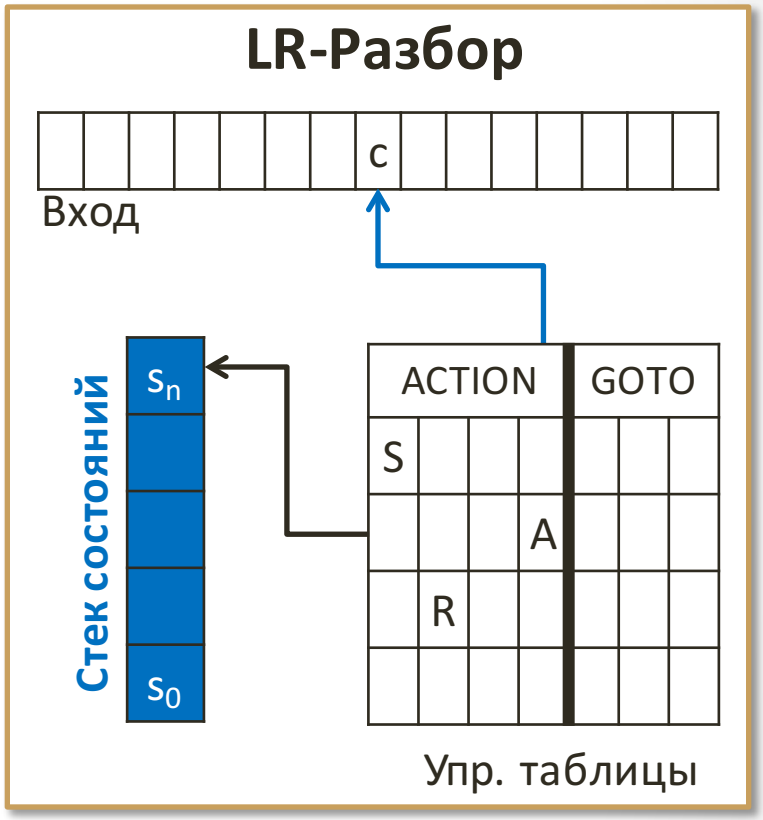

- Управляющие таблицы **не меняются** (для данного языка)
- **Измененяемое состояние**:
  - Стек состояний парсера
  - Позиция считывающей головки
- Основная идея абстрактного разбора
  - Для каждой **позиции** во входном **автомате**
    - Вычислить **множество всех** возможных **стеков** состояний парсера

Алгоритм

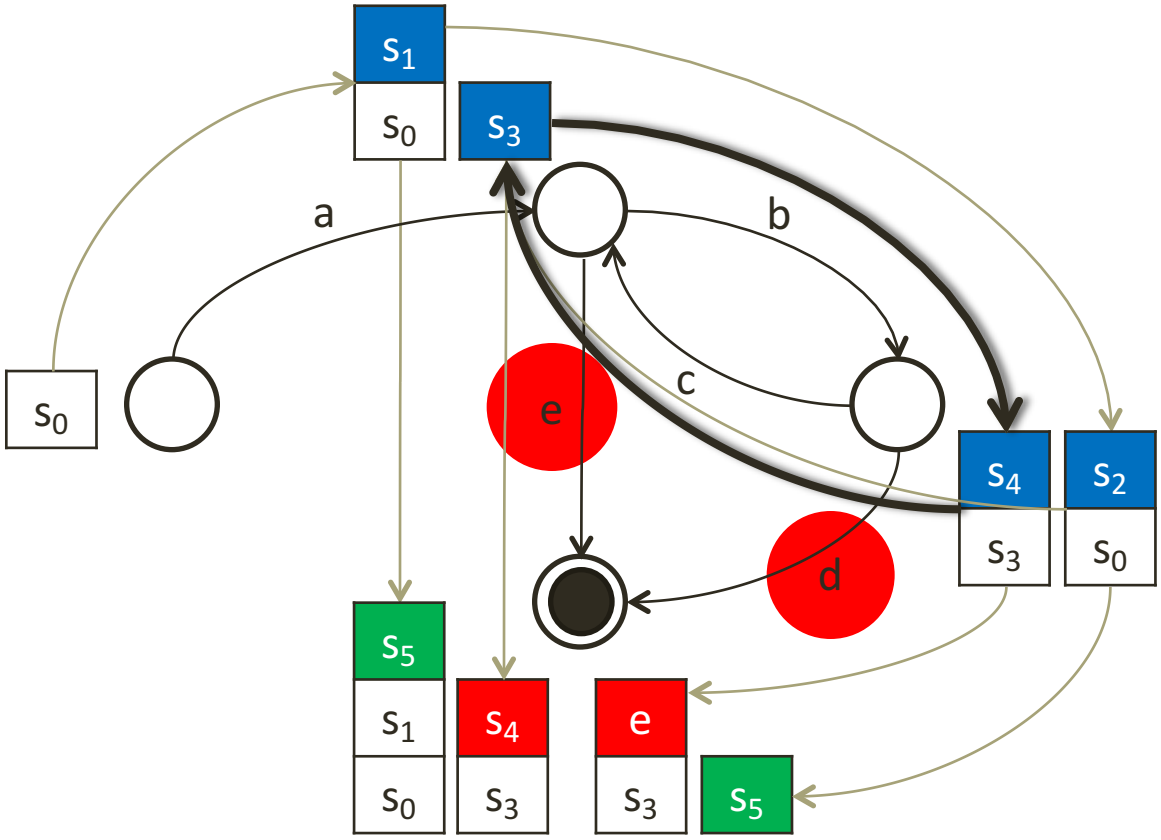

Время работы

- S_{in} – множество состояний входного автомата
- S_p – множество управляющих состояний парсера
- $Stacks(S_P)$ – множество стеков состояний парсера

- Время работы алгоритма
  - $O(|S_{in}|*|Stacks(S_p)|)$ **= ∞, задача неразрешима!**

- Регулярная аппроксимация
  - **Ограничим глубину стеков** состояний парсера числом **D**
  - $O(|S_{in}|*|Stacks(S_p)|) = O(|S_{in}|*|S_p|^D) < \infty$

Поиск контрпримеров

- Пользователю нужно показать, **какую именно** неправильную строку может сформировать его программа
  - **Контрпример** – путь в **графе стеков**, заканчивающийся **ошибочным** состоянием
  - Обычно нас интересует **самый короткий** контрпример
- **Как решать?**

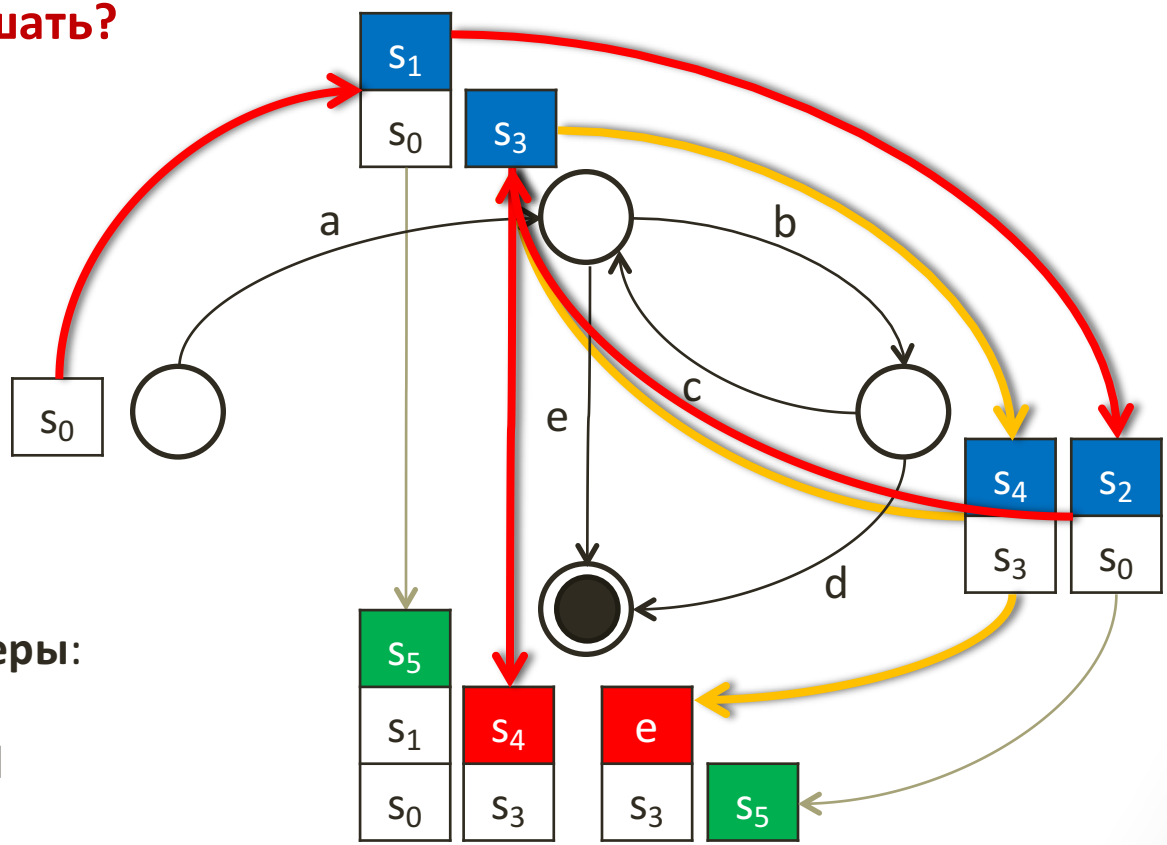

Контрпримеры:

a(bc)+e

ab(cb)+d

Технические требования

- Нужно сообщать об ошибках в процессе написания кода
  - **нужны инкрементальные алгоритмы**

- Подход должен единообразно поддерживать разные встроенные языки

  - **Хотелось бы** просто описывать синтаксис (контекстно-свободной) **грамматикой**
  - **Не хотелось бы** создавать такие грамматики вручную. Лучше взять готовую, например, из **стандарта языка**.
  - Грамматики, приводимые в стандартах, **содержат множество неоднозначностей**

Что я не рассказал

- Abstract GLR-Parsing
  - Возможность работать с неоднозначными грамматиками
- Abstract Lexical Analysis
  - Входной алфавит парсера на самом деле не Unicode, а алфавит лексем: ключевых слов, идентификаторов, констант...
    - **Как сконвертировать один автомат в другой?**
- Как проверять отсутствие опечаток в идентификаторах
  - Автоматические тесты
  - **[Открытый вопрос]** Булевские грамматики
- Метод можно **обобщить** так, что для любого ***автоматного предиката*** можно
  - Проверить его истинность на регулярном множестве строк
  - Найти кратчайший контрпример

Темы дипломных работ

1. [М] Использование **булевских грамматик** и Abstract Parsing для обнаружения опечаток в **идентификаторах**

2. [М] Мспользование **булевских грамматик** для реализации **автодополнения** идентификаторов в SQL-запросах

3. [Б] Оптимизация **регулярной абстракции**: ограничивать глубину стека только там и так, где и как это необходимо

4. [Б] Оптимизация потребления памяти **GLR Abstract Parsing** – разработка и реализация эффективных структур данных для хранения множества множеств стеков