Проект технологии извлечения знаний из исходных текстов на языках C++ и C# с использованием общего промежуточного представления

Пустыгин А.Н., Ошнуров Н.А., Ковалевский А.А.
Челябинский Государственный Университет

Этапы преобразования исходных текстов для извлечения знаний разработчика

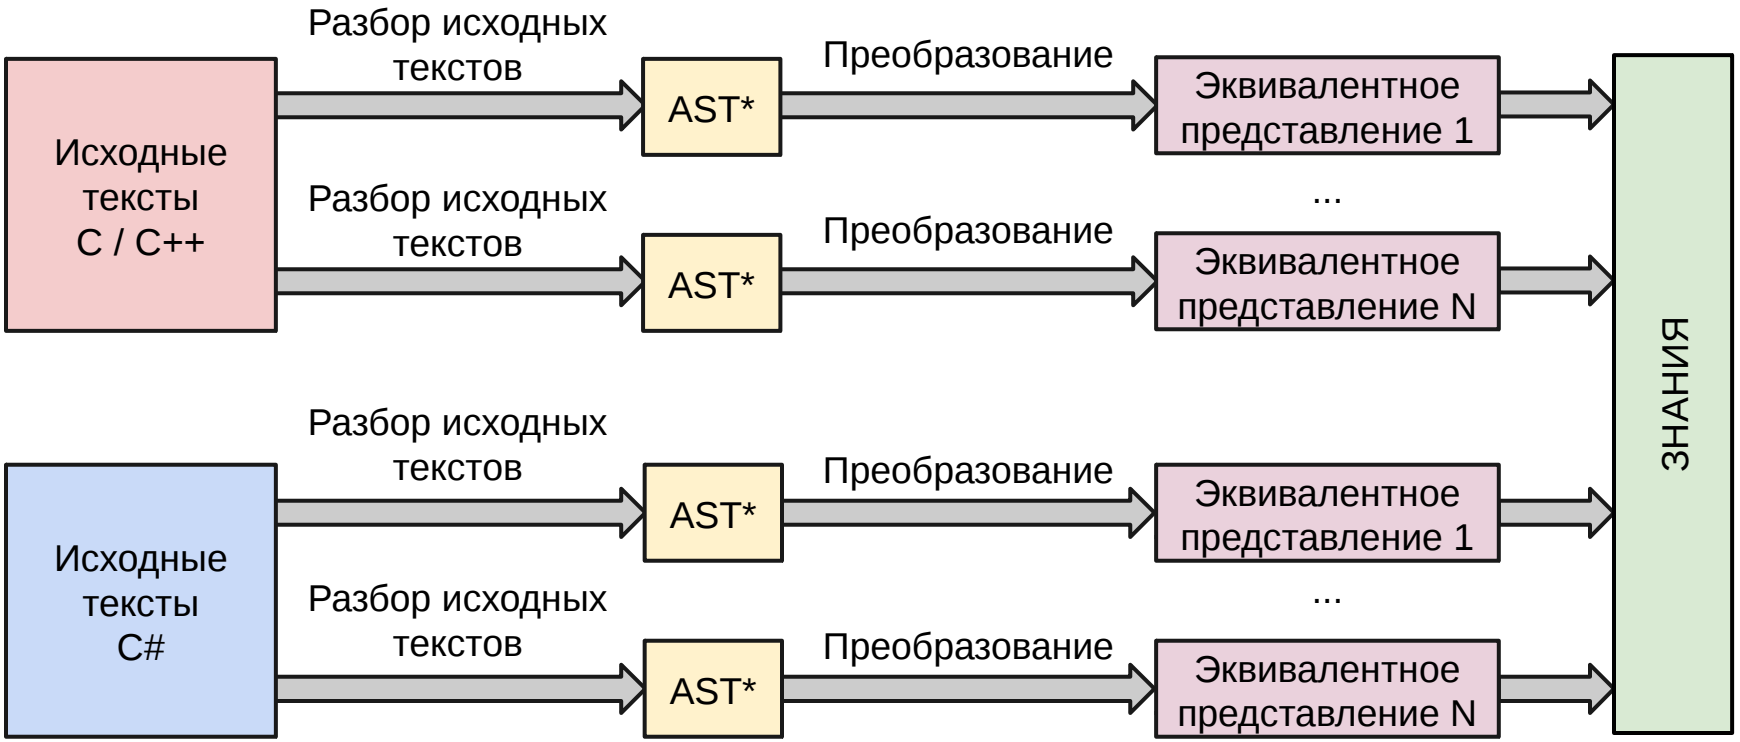

AST* - набор данных, являющихся результатом синтаксического разбора

Использование промежуточного представления для сокращения необходимого времени

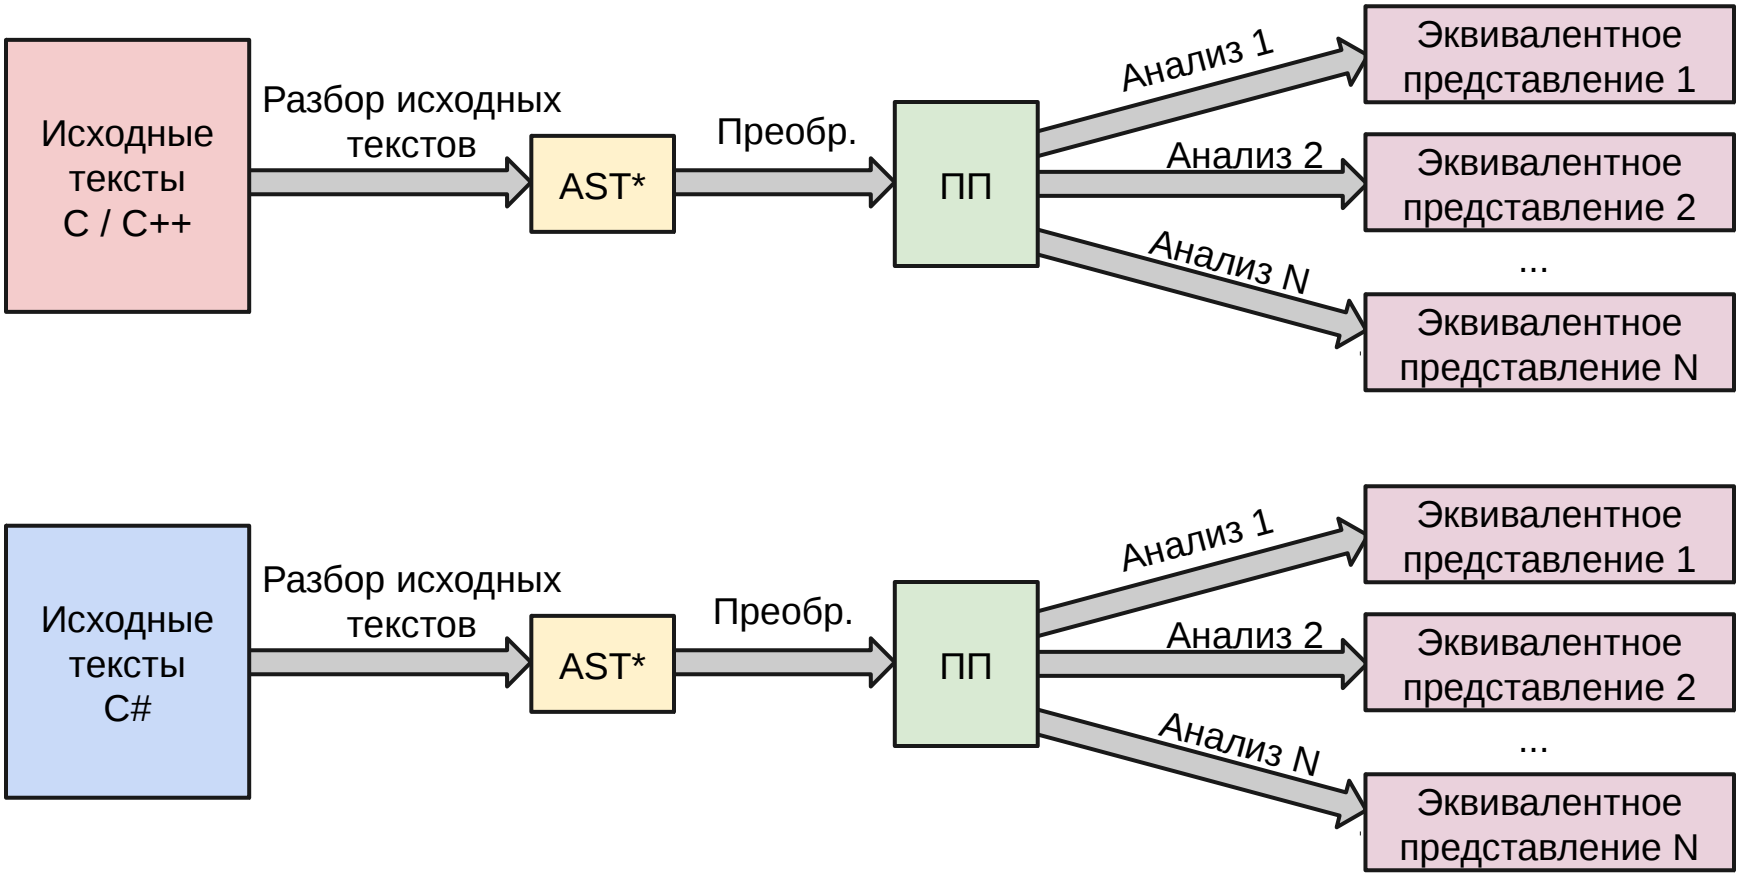

ПП - промежуточное представление

Универсальное промежуточное представление — способ унификации генераторов эквивалентных предсталений

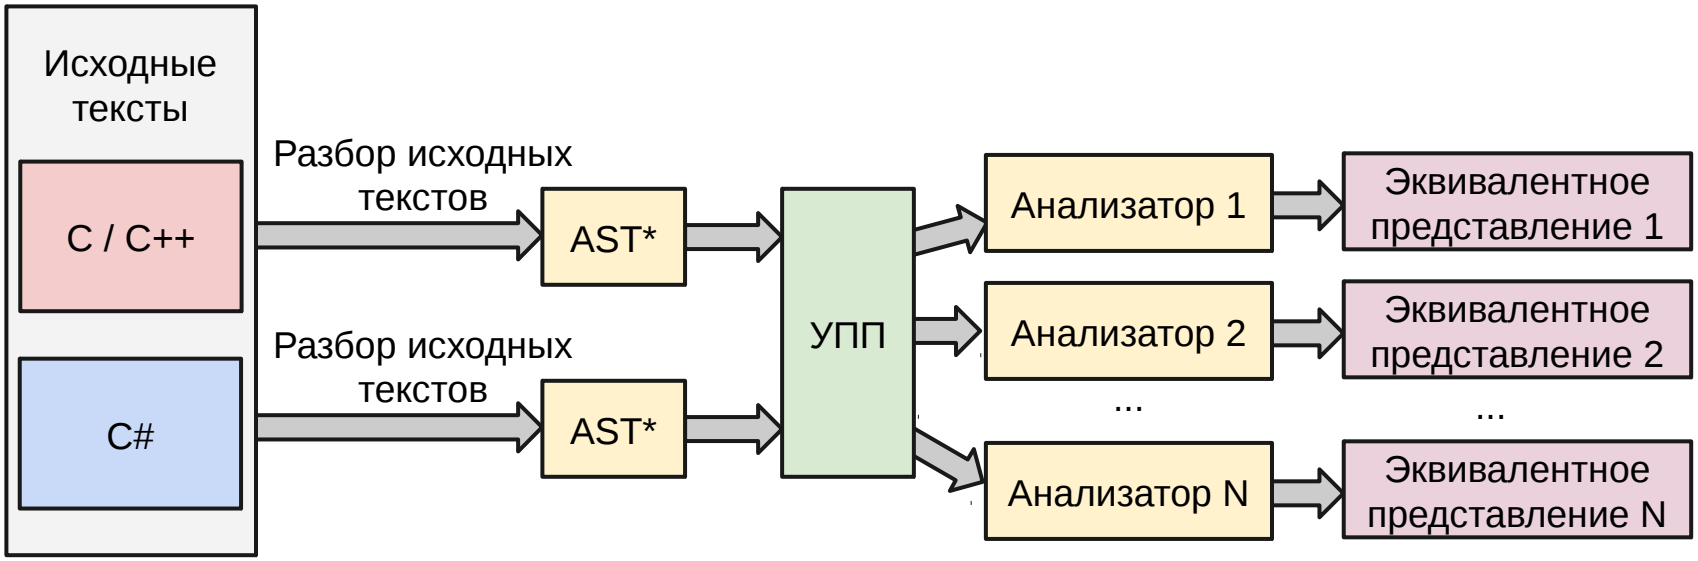

УПП - Универсальное промежуточное представление

Задачи построения набора инструментов для языков ветви C

- Предложить формат для построения промежуточного представления гетерогенных текстов на C/C++ и C#,
- Спроектировать инструменты для получения такого представления.

Критерии построения формата промежуточного представления

1. Универсальность - отображение всех синтаксических конструкций языков, содержащихся в стандарте
2. Расширяемость - возможность введения новых конструкций языка, при переходе на новую версию
3. Расширяемость для подключения синтаксических конструкций новых языков
4. Текстовый формат промежуточного представления, позволяющий использование инструментов для обработки текста

Существующие промежуточные представления для языков ветви C

- SrcML - документо-ориентированное XML представление исходного кода, дополненное информацией из AST.
- Поддерживает языки:
  - C/C++ (CppML)
  - Java (JavaML)
  - C# (SrcML.Net)
- Промежуточное представление содержит полный исходный текст, встроенный между тегами

Недостатки формата SrcML - 1

- Зависимость представления пространства имен от языка:

  Разделитель пространства имен в C# и Java обозначен как «.»

  Разделитель пространства имен в C++ обозначен как «::»

- Поскольку для обозначения типа применяется конструкция:

  `<type><name>type_name</name></type>,`

  то пользовательские типы не отличимы встроенных.

- Отсутствует атрибут или тег типа идентификатора, а также атрибут-ссылка на его объявление (в документации id_ref):

  `myVar → <name>myVar</name>`

Недостатки формата SrcML - 2

- Не распознает ключевое слово this

  this → <name>**this**</name>

- Не распознает модификаторы доступа

  public → <name>**public**</name>

- Нет раздельного объявления для пользовательских типов и встроенных:

  class Tool → <decl>**class** <name>Tool</name></decl>

  int len →

  <decl><type><name>**int**</name></type>
  <name>len</name></decl>

Результаты обзора существующих форматов

В связи с отсутствием удовлетворяющих заданным критериям формата промежуточного представления и инструментов для его извлечения был произведен поиск инструментов для извлечения AST как крайнего из доступных универсальных наборов данных об исходном тексте

Свободные инструменты для получения AST C++

Инструмент	Преимущества	Недостатки
ROSE Compiler	Поддержка C++ 11	Не является встроенным компилятором операционной системы
Eclipse CDT	IDE для статического анализа. Поддержка C++	Отсутствие поддержки C++11
Mozilla Dehydra & Treehydra (GCC GIMPLE)	Извлечение информации о некоторых узлах AST	Разработка приостановлена в 2010. Неполное и неэквивалентное исходному тексту AST
Clang и его библиотека libclang	Поддержка C++11, активное сообщество, поддержка Google, Apple, пришел на замену GCC в FreeBSD	-

Свободные инструменты для получения AST C#

Инструмент	Преимущества	Недостатки
Mono C# Compiler	Кроссплатформенность решения (Windows, GNU/Linux, MacOS, iOS, Android)	Несовместимость API разных версий компилятора.
ICSharpCode NRefactory	Поддерживает C# 5.0, предоставляет инструментарий для преобразования исходного кода	-

Текстовые форматы представления структурированных данных

- JSON — текстовый формат обмена данными, основанный на JavaScript и обычно используемый именно с этим языком.
- YAML — человекочитаемый формат сериализации данных, близкий к языкам разметки, но ориентированный на удобство ввода-вывода типичных структур данных многих языков программирования
- XML — рекомендованный Консорциумом Всемирной паутины (W3C) язык разметки.

Существующие программные инструменты, предназначенные для обработки текстов XML

- XPath [W3C] - язык запросов для выборки и навигации по XML документу, вычисления его метрик
- XQuery [W3C] - функциональный язык запросов и трансформаций XML документа
- XSLT [W3C] - язык для трансформации XML документа в другие его эквивалентные представления (XML, SVG, PDF, PNG)
- XML-базы данных (Sedna [Apache License 2.0], BaseX [BSD]) - как единое хранилище знаний об исходном коде проекта

Пример запроса извлечения данных из XML-текста на языке Xpath

Текст XML:

```
<Project>
    <Class name="IHuman" kind="interface"></Class>
    <Class name="Doctor" kind="class"></Class>
    <Class name="Programmer" kind="class"></Class>
    <Class name="IAnimal" kind="interface"></Class>
    <Class name="Bird" kind="class"></Class>
</Project>
```

Пример запроса для получения списка интерфейсов в проекте:

```
//Class[@kind="interface"]/@name
```

Результат:

```
name=IHuman,name=IAnimal
```

Пример запроса извлечения данных из XML-текста на языке XQuery

Текст XML:

```
<Project>
    <Class name="IHuman" kind="interface"></Class>
    <Class name="Doctor" kind="class"></Class>
    <Class name="Programmer" kind="class"></Class>
    <Class name="IAnimal" kind="interface"></Class>
    <Class name="Bird" kind="class"></Class>
</Project>
```

Пример запроса для получения списка интерфейсов в алфавитном порядке:

```
for $x in doc('test')//Class[@kind="interface"]/@name
order by $x
return string($x)
```

Результат: IAnimal, IHuman

Технология извлечения знаний из исходных текстов с применением XML СУБД

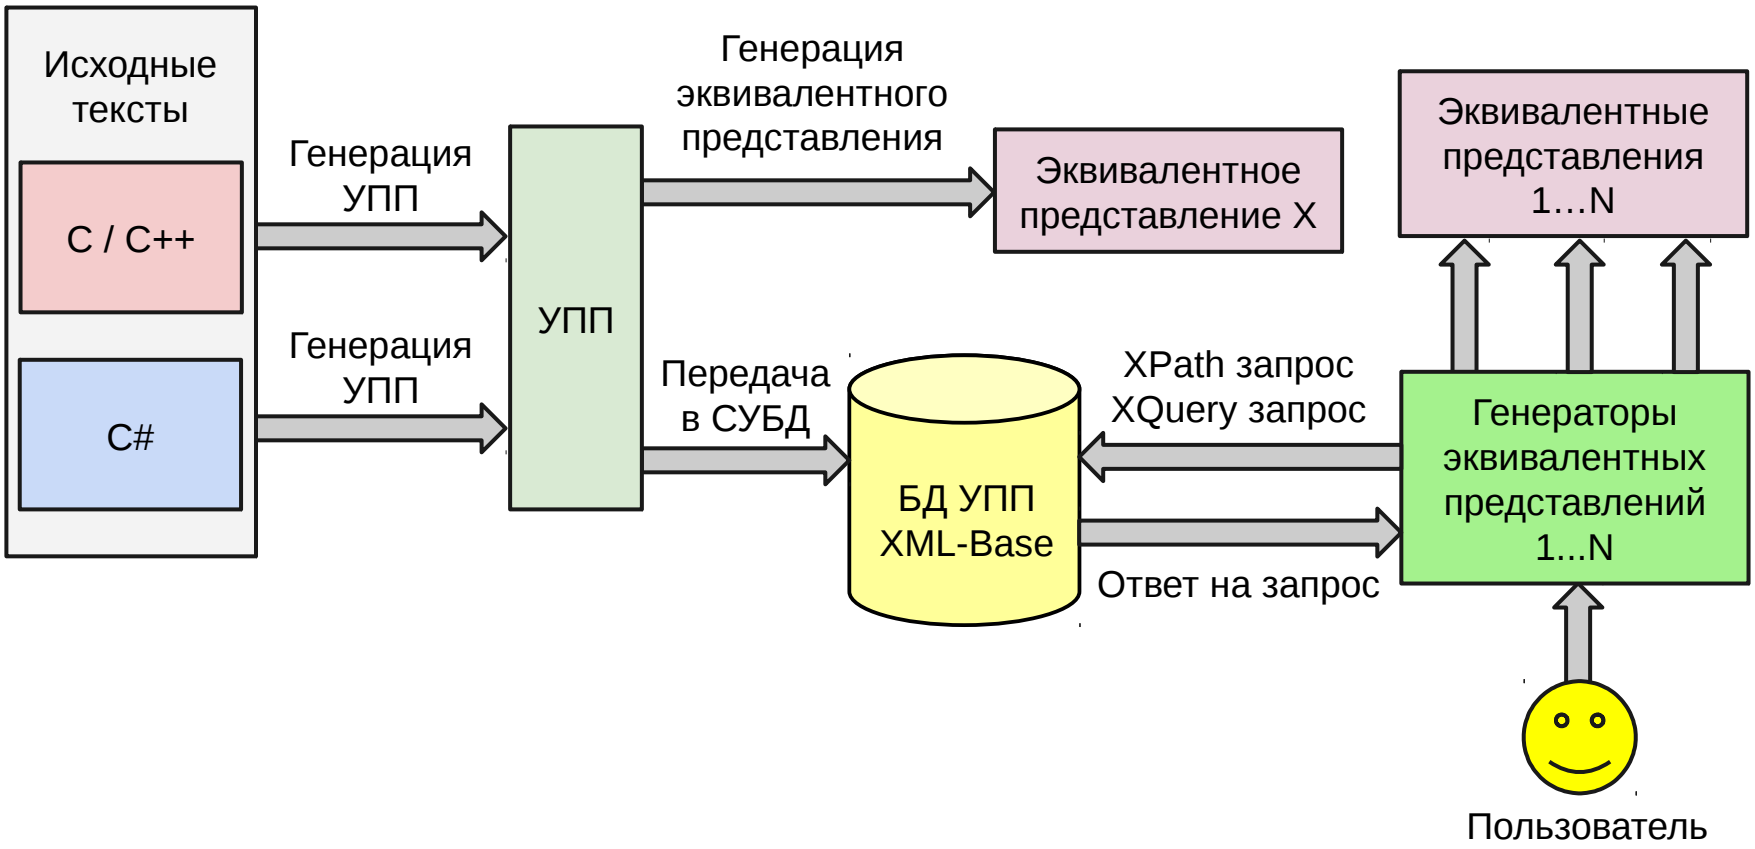

Группы синтаксических конструкций в формате промежуточного представления

- Общие или частично совпадающие
  - Операторы потока управления (for, if, while, switch)
  - Арифметические операторы (+, -, *, ++)
  - Объявления классов, методов, их вызовов и т.д.
  - Директивы препроцессора
- Частные C++
  - Типы наследования
  - Шаблоны как средство метапрограммирования
- Частные C#
  - Linq
  - Делегаты
  - Атрибуты
  - async / await и т.д.

Примеры синтаксиса в формате промежуточного представления

Исходный текст (условный переход):

```
if(a > 2){    } else { }
```

Представление:

```
<If>
  <Condition>
      <op:Binary kind="greater">
          <VarRef ref="1" name="a" />
          <lit:Integer value="2" />
      </op:Binary>
  <Condition>
      <Then />
  <Else />
</If>
```

Примеры синтаксиса в формате промежуточного представления

Исходный текст (вызов метода объекта):

```
obj.Foo(1.5f);
```

Представление:

```
<Call>
  <Target>
      <VarRef ref="1" name="obj" />
  </Target>
  <Exec>
      <MethodRef name="Foo" ref="511" def="512" decl="513" />
  </Exec>
  <Args>
      <Arg><lit:Float value="1.5f" /></Arg>
  </Args>
</Call>
```

Примеры синтаксиса в формате промежуточного представления

Исходный текст (объявление переменной):

```
MyClass obj();//C++
MyClass obj= new MyClass();//C#
```

Промежуточное представление:

```
<VarDecl name="obj" id="500">
 <Type name="MyClass" kind="class" ref="100" />
 <Init>
     <Call>
         <Exec>
           <MethodRef name="MyClass" ref="110" def="111"
      decl="111"/>
         </Exec>
      </Call>
 </Init>
</VarDecl>
```

Примеры синтаксиса C# в формате промежуточного представления

Исходный текст (объявление делегата):

```
public delegate void Foo();
```

Промежуточное представление:

```
<cs:Delegate id="256" name="Foo">
  <Modifiers>
      <Modifier name="public" />
  </Modifiers>
  <Return>
      <Type name="void" kind="void" />
  </Return>
</cs:Delegate>
```

Примеры синтаксиса C# в формате промежуточного представления

Исходный текст (Linq запрос списка атрибутов Name объектов коллекции):

```
from x in col select x.Name;
```

```
<cs:Query>
 <cs:FromClause>
  <Arg id="128" name="x" />
  <InExpr><VarRef ref="129" name="col" /></InExpr>
  <cs:QueryBody>
   <cs:QueryBodyOperation>
   <cs:SelectClause>
    <Src><Call>
     <Target><VarRef ref="128" name="x" /></Target>
     <Exec><PropertyRef ref="130" name="Name" /></Exec>
    </Call></Src>
   </cs:SelectClause>
   </cs:QueryBodyOperation>
  </cs:QueryBody>
 </cs:FromClause>
</cs:Query>
```

Примеры синтаксиса C++ в формат промежуточного представления

Исходный текст (объявление шаблонного класса):

```
template<class T,int Size = 100>
class Set{ };
```

Представление:

```
<GenericParams>
  <GenericParam name="T" kind="class" />
  <GenericParam name="Size" kind="type">
        <Type name="int" kind="internal" />
        <Default><lit:Integer value="100" /></Default>
   </GenericParam>
</GenericParams>
<Class name="Set" />
```

Статистика вариантов синтаксиса в формате промежуточного представлени

Всего 136 узлов из них

- 98 узлов общих для C++ и C#
- 32 узла специфичных для C#
- 6 узлов специфичных для C++

Результаты

- Был предложен проект технологии для извлечения знаний из исходных текстов
- Был разработан формат универсального промежуточного представления для языков C/C++ и C#: http://tiny.cc/UIR