Проектирование компиляторов

Лекция 4.
Семантический анализ.

Маркин А. Л.
alexanius@gmail.com

2021

Компиляция программы

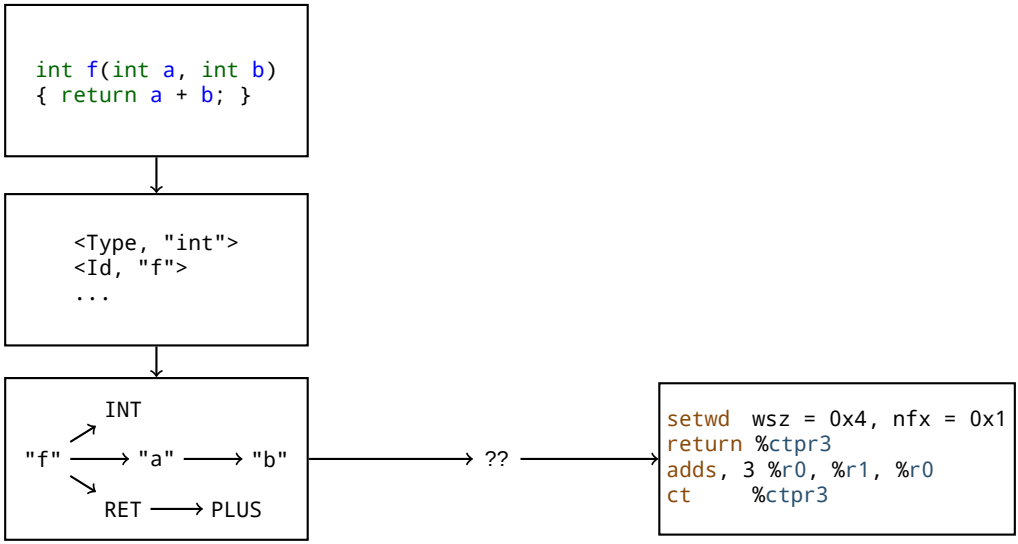

Компиляция программы

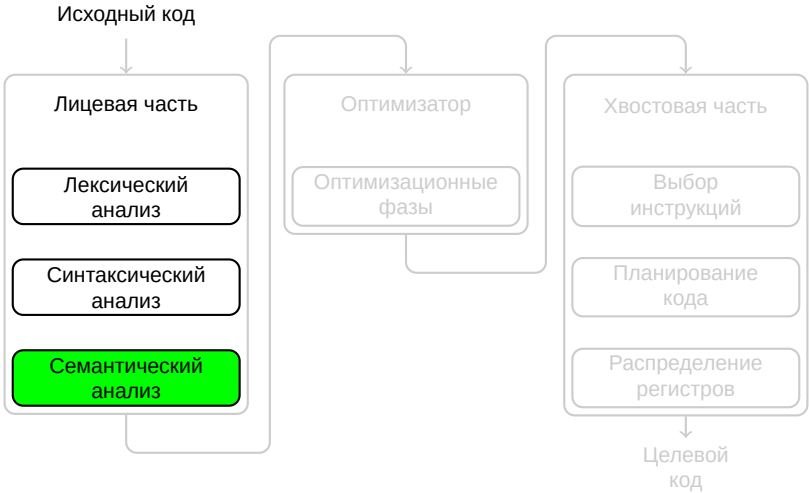

Проблема

```
int f(int * a)
{
   return b;
}
```

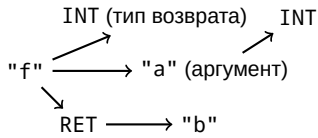

Проблема

```
int f(int * a)
{
   return b;
}
```

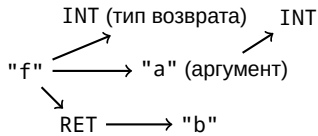

С точки зрения синтаксиса программа правильна, однако с точки зрения стандарта Си она содержит ошибку.

Контекстно-свободные грамматики не умеют отвергать программы, содержащие «логические» ошибки.

Проблема

```
int f(int * a)
{
   return b;
}
```

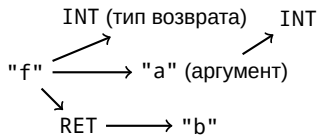

Для выявления обращений к несуществующим идентификаторам следует запоминать все **объявленные** идентификаторы, а в узлах обращения к ним следует проверять наличие этих идентификаторов.

Таблица символов

```
int f(int * a)
{
   return b;
}
```

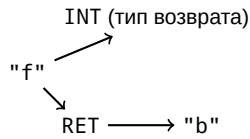

Таблица символов
"a"

Одним из способов проверки существования объектов является поиск по **таблице символов**.

Таблица символов

Таблица символов связывает идентификатор с объектом. Работа с таблицей символов производится по следующему принципу:

- При обработке узла дерева разбора с объявлением переменной, идентификатор заносится в таблицу. Сам узел перестаёт быть нужным и может быть удалён.
- При обработке узла, содержащего идентификатор производится поиск этого идентификатора, узел начинает ссылаться на найденную запись.
- Если запись не найдена, то это означает использование объекта без его определения, что считается ошибкой.

Проблема

```
int f(int i)
{
   {
      int i;
      i = 20;
   }
   {
      int i;
      i = 30;
      return i;
   }
}
```

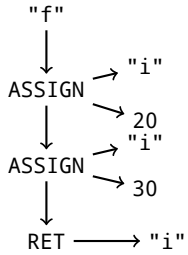

Проблема

```
int f(int i)
{
   {
      int i;
      i = 20;
   }
   {
      int i;
      i = 30;
      return i;
   }
}
```

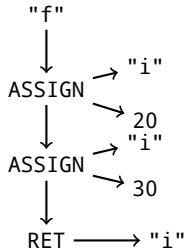

Таблица символов
"f"
"i"
??? "i"???
??? "i"???

С точки зрения языка Си программа правильная. Но в таблице не может находиться несколько записей с одним ключом.

Область видимости

Область видимости (scope) — область программы, в которой идентификатор связан с конкретным объектом.

Каждая область видимости будет обладать собственной таблицей символов.

```
int f(int i)
{
   {
      int i;
      i = 20;
   }
   {
      int i;
      i = 30;
      return i;
   }
}
```

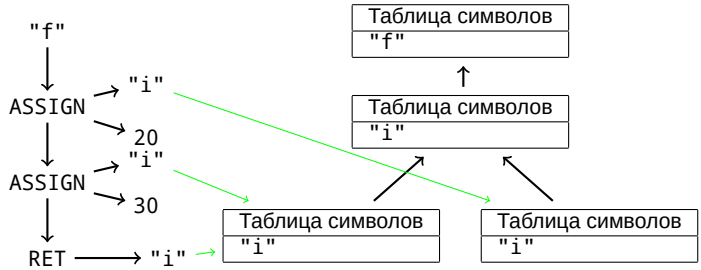

Область видимости

Обычно таблица символов представляет из себя структуру «вывернутого дерева», т.к. дуги в ней идут от к родителям.

Каждый узел таблицы символов привязан к области видимости программы. Для определения соответствия объекта и идентификатора применяется следующий алгоритм:

1. Ищем идентификатор в текущей таблице символов.
2. Если идентификатор найден — привязываем запись таблицы к узлу дерева разбора.
3. Если идентификатора в таблице нет — переходим к родительской таблице и повторяем п. 1.
4. Если родительская таблица отсутствует, то объекта с таким идентификатором в данном участке программы не существует.

Область видимости

Области видимости можно поделить на:

- **Статическая** (lexical scope) — идентификатор привязывается к объекту на основе кода программы. Используется почти всеми языками.
- **Динамическая** (dynamic scope) — идентификатор привязывается к объекту на основе контекста исполнения. Характерно для языка bash, некоторых диалектов lisp.

Область видимости

Возможные привязки идентификаторов:

- Выражение
- Лексический блок
- Функция
- Файл
- Модуль
- Глобальная

Проблема

```
void f(char * c)
{
   c = 10;
}
```

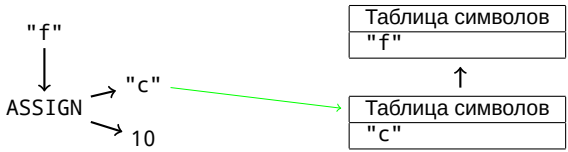

Проблема

```
void f(char * c)
{
   c = 10;
}
```

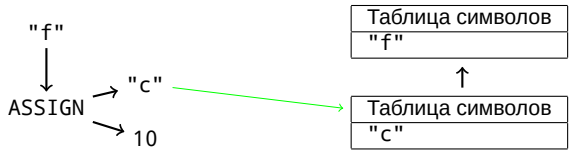

Ещё один случай синтаксически правильной программы, содержащей ошибку. Здесь происходит попытка присвоить объекту типа `char *` значение типа `int`.

Типы в компиляторе

```
void f(char * c)
{
   c = 10;
}
```

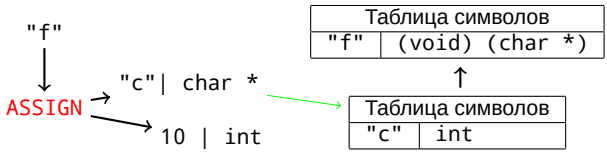

Типы в компиляторе

```
void f(char * c)
{
   c = 10;
}
```

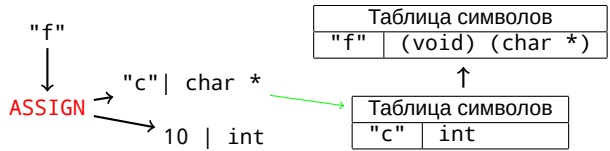

Ещё один случай синтаксически правильной программы, содержащей ошибку. Здесь происходит попытка присвоить объекту типа `char *` значение типа `int`.

Типы в компиляторе

Таблица символов служит не только для определения факта наличия связи идентификатора с объектом, но и для хранения информации об объекте, в том числе о его типе.

Одной из задач семантического анализа является простановка узлам дерева разбора их типов, также поиск ошибок, связанных с типами.

Дерево разбора с полной информацией о типах и построенной таблицей символов называется **деревом абстрактного синтаксиса**.

Типы в компиляторе

Тип — множество возможных значений и операций над ними.

Система типов языка описывает какие операции допустимы для данных типов.

Проверка типов языка определяет корректность программы с точки зрения системы типов.

Типы в компиляторе

Типы бывают:

- Базовые (интегральные): простые типы, изначально известные компилятору: `int`, `float`, `bool` и т.п.
- Пользовательские: программист сам создаёт тип: структуры, объединения.
- Агрегатные: массивы объектов заданного типа.

В современные компиляторы могут быть встроены типы, не являющиеся базовыми, например векторные типы, представляющие из себя структуры.

Типы в компиляторе

Операции могут совершаться только с объектами эквивалентных типов. Сама по себе эквивалентность понимается в каждом языке по-разному.

- Каждый тип эквивалентен сам себе.
- Типы являются структурно-одинаковыми (например в языке Питон. В языке Си это утверждение неверно).

Часто возникает ситуация когда аргументами выражения являются объекты разных типов: `int a = 1 + 0.3;`. В таких случаях в зависимости от правил языка должно произойти либо приведение одного из аргументов к нужному типу, либо выведено сообщение об ошибке.

Типы в компиляторе

Способы проверки типов:

- **Статические** — почти все проверки типов выполняются во время компиляции (C, C++, Java).
- **Динамические** — почти все проверки типов выполняются во время исполнения (Python, Scheme).

Также бывают языки без проверки типов, например ассемблер и машинный код. Тем не менее, разработчики аппаратуры стремятся устранить это упущение, например: «защищённый режим» в процессорах Эльбрус, MTE — расширение системы команд ARM, и другие.

Типы в компиляторе

- Статические проверки типов:
  - Позволяют выявлять ошибки во время компиляции
  - Позволяют не тратить время на проверку типов во время исполнения

- Динамические проверки типов:
  - Упрощают и ускоряют прототипирование на данном языке

Типы в компиляторе

Ещё одной характеристикой системы типов в компиляторе является строгость её проверок:

- **Сильная** система типов позволяет производить операции только для объектов эквивалентных типов. Попытки произвести операции над не эквивалентными типами приводят к ошибке.
- **Слабая** система типов позволяет неявно для программиста строить операции приведения объекта одного типа к другому.

Система типов в языках

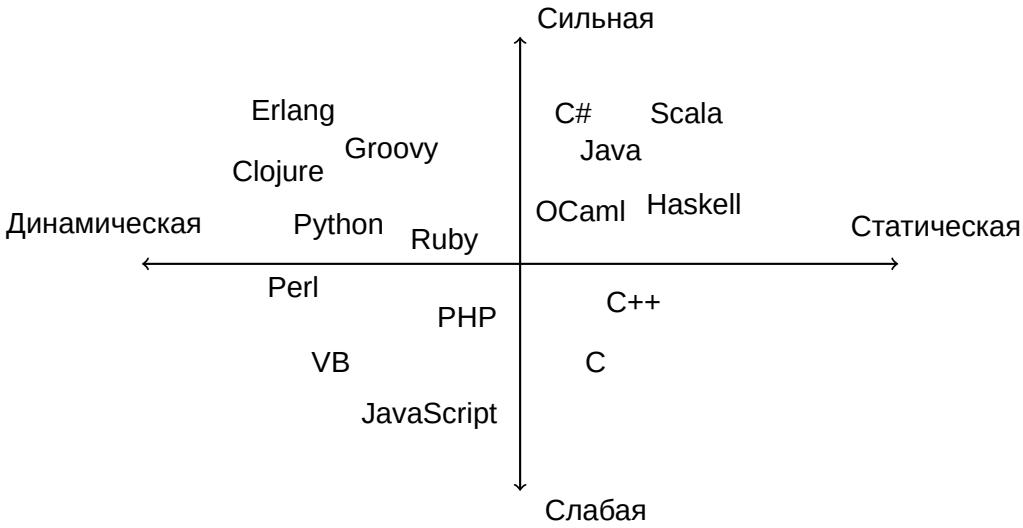

Ошибки проектирования языков

В языке Си существует конструкция, которую невозможно правильно распознать без семантической информации:

```
(A)*B
```

Ошибки проектирования языков

В языке Си существует конструкция, которую невозможно правильно распознать без семантической информации:

```
(A)*B
```

Данная конструкция может быть:

- Умножением двух переменных: `A * B`
- Приведением к типу `A` разыменованной переменной `B`: `(A)(*B)`

Одним из способов решения проблемы (классическим) является заполнение и использование таблицы символов на этапе лексического анализа. Такой способ называется **lexer hack**.

Ошибки проектирования языков

Крупной ошибкой проектирования является язык JavaScript:

```
> [] + []
< ""

> [] + {}
< "[object object]"

> {} + []
< 0

> true+true+true === 3 - true
< true

> true - true
< 0
```

```
> true == 1
< true

> true === 1
< false

> (!+[]+[]+![]).length
< 9

> 9 + "1"
< "91"

> 91 - "1"
< 90
```

Заключение

Работа семантического анализатора состоит из двух частей:

1. Построение дерева абстрактного синтаксиса:
   - Заполнение таблицы символов
   - Дополнение информацией узлов дерева разбора, устранение лишних узлов
2. Выявление смысловых ошибок в программе:
   - Ошибки объявления идентификаторов
   - Неправильное с точки зрения типов взаимодействие объектов узлов
   - Неправильное количество аргументов в вызываемых функциях и т.п.
   - Прочие специфичные для конкретного языка ошибки

Заключение

Обычно работа лексического, синтаксического и семантического анализатров не имеет такой чёткой границы как в описывается теории. Это может быть связано как с архитектурой языков, так и с соображениями времени компиляции.

Дерево абстрактного синтаксиса хорошо подходит для описания программы приближённого к языку программирования, но использовать его для дальнейшей компиляции не так удобно.

Для продолжения работы с компилятором, лицевая часть должна перевести дерево абстрактного синтаксиса в промежуточное представление этого компилятора.

Литература

- *А. В. Ахо, М. С. Лам, Р. Сети, Д. Д. Ульман* Компиляторы: принципы, технологии и инструменты.
- *K. D. Cooper, L. Torczon* Engineering a compiler.
- *A. Aiken* CS143 Compilers. Stanford lectures.
- *Р. Хантер* Основные концепции компиляторов