Анализ кода и информационная безопасность

Лекция 04

Статический анализ исходного кода с целью поиска ошибок

МГУ / ВМК / СП

0401

СТАТИЧЕСКИЙ АНАЛИЗ ИСХОДНОГО КОДА ДЛЯ ПОИСКА ОШИБОК

Анализ программ

- Анализ программы — выявление фактов о программе:
  - статический анализ — анализ программы без её запуска;
  - динамический анализ — анализ программы, использующий её выполнение (например, тестирование).
- Статический анализ:
  - оптимизация программ (компилятор);
  - рефакторинг (среда разработки);
  - автоматическое документирование (Doxygen);
  - обфускация и деобфускация программ (Dotfuscator, Ariadne);
  - оценка метрик программы (качество, сложность, время работы…);
  - поиск ошибок (FindBugs, Coverity, Klocwork, Svace).

Статический поиск ошибок

- Неформальный подход — поиск часто встречающихся ошибок:
  - перекрёстная проверка кода:
    - выполняется вручную;
    - у людей похожие «слепые пятна» при просмотре кода;
  - анализ на уровне синтаксиса — автоматический поиск ошибочных шаблонов в коде.
- Формальный подход — поиск всех ошибок или доказательство их отсутствия:
  - верификация — формальное доказательство соответствия программы её спецификации:
    - требует построения спецификации;
  - проверка свойств — например, «программа не выбрасывает NullPointerException».

Анализ на уровне синтаксиса

- Автоматизация ручной проверки кода.
- Более объективный анализ (нет «слепых пятен»).
- Поиск по достаточно ограниченным (локальным) шаблонам.
- Не подходит для проверки свойств на длинных путях программы.

```
if (X = Y) {
   // ...
}
```

```
for (int X; X < Y; X++) {
   // ...
}
```

Верификация

- Золотой стандарт, даёт наибольшую гарантию корректности программы.
- Используются формальные методы:
  - доказательство теорем;
  - проверка моделей.
- Необходима полная спецификация программы.
- Анализ потока данных по всем возможным путям программы.
- Слишком дорогой метод для массового применения:
  - большие временные затраты по разработке спецификации;
  - высокие требования к разработчикам спецификации;
  - процесс проверки может быть очень долгим.
- Применяется в критически важных системах (космос, транспорт, энергетика…).

Проверка свойств

- Не требуется спецификация программы.
- Используются общие стандартные спецификации безопасности — описывается корректная работа с ресурсами:
  - «семафор должен быть освобождён после захвата и захвачен только после освобождения»;
  - «память не должна использоваться после того, как была освобождена, и не должна освобождаться дважды».
- В случае простых свойств для описания могут использоваться конечные автоматы.

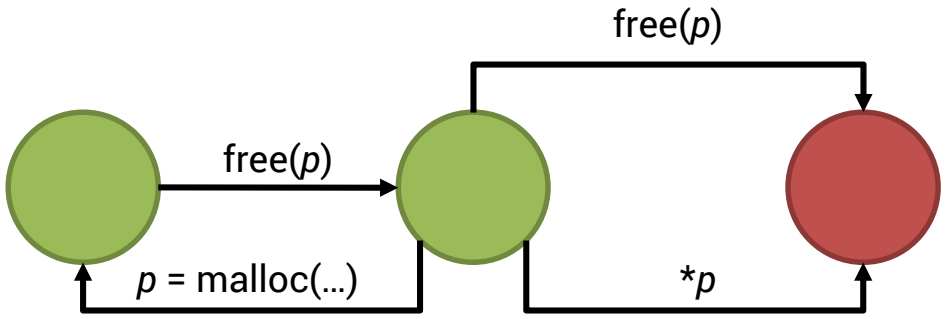

Ограничения формального подхода

- Задача автоматической проверки нетривиального свойства произвольной программы алгоритмически неразрешима (теорема Райса):
  - «есть ли в программе *P* ошибка класса *x*?»;
  - «достигает ли программа *P* состояния *Y*?»;
  - проблема останова.
- Невозможно реализовать универсальную проверку свойств, но для конкретной программы задача разрешима.
- Проверка свойств подразумевает две характеристики:
  - полнота — обнаруживаются все ошибки;
  - безошибочность — отсутствуют ложные срабатывания.
- Поиск ошибок (в отличие от верификации) — отказ от одного или обоих свойств.

Анализ состояний программы

- Отказ от безошибочности:
  - анализ надмножества возможных состояний;
  - гарантирует полноту (все истинные ошибки и, возможно, ложные срабатывания);
  - тривиальная реализация — ошибка в каждом операторе.
- Отказ от полноты:
  - анализ подмножества состояний;
  - гарантирует безошибочность (все выданные ошибки истинные);
  - тривиальная реализация — не выдавать срабатываний.

Анализ состояний программы

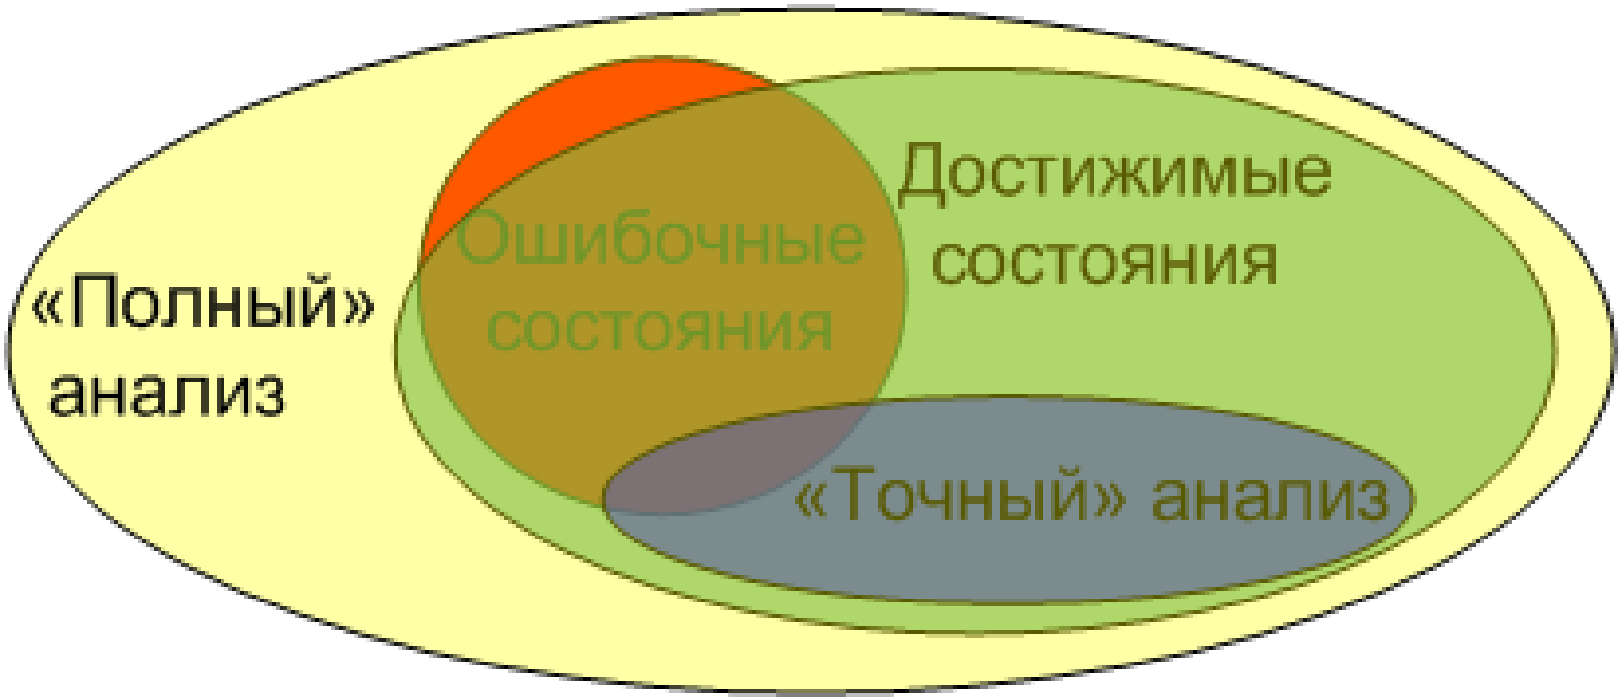

Основное ограничение статического анализа

- Экспоненциальный взрыв — быстрый рост числа путей в программе с увеличением объёма кода.
- Каждое ветвление увеличивает число путей в два раза.
- Что можно сказать про циклы?
- Вывод — анализ, проводимый вдоль всех путей, неприменим к реальным программам.
- Возможное решение — группировка путей, объединение состояний в точках слияния нескольких путей:
  - may-анализ — анализ надмножества состояний (объединение);
  - must-анализ — анализ подмножества состояний (пересечение).

Пример may-анализа

```
int
f(bool flag)
{
    char *buf;
    int i;

    if (flag) {
        i = 5;
        buf = malloc(10);       // i = 5, sizeof(buf) = 10
    } else {
        i = 15;
        buf = malloc(20);       // i = 15, sizeof(buf) = 20
    }

    // i ∈ { 5, 10 }, sizeof(buf) ∈ { 10, 20 }
    buf[i] = 0;
}
```

Оценка качества анализа

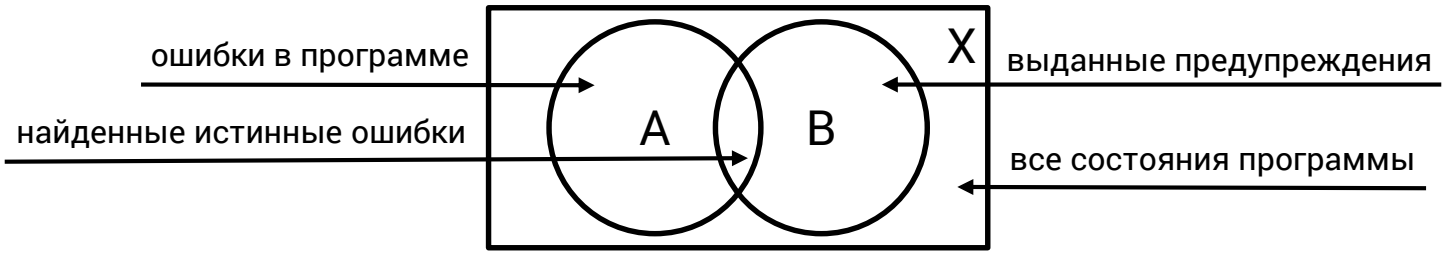

- B \ A — ложные срабатывания (false positive);
- A \ B — не найденные ошибки (false negative);
- A ∩ B — найденные истинные ошибки (true positive);
- X \ A \ B — состояния без ошибок, не выданные анализатором (true negative);
- Характеристики:
  - полнота — доля найденных истинных ошибок среди всех ошибок: $\frac{|A \cap B|}{|A|}$;
  - точность — доля найденных истинных ошибок среди всех срабатываний: $\frac{|A \cap B|}{|A|}$.

0402

МОДЕЛИ ПРОГРАММЫ

Модели программы

- Исходный код как представление для анализа неудобен.
- Используются модели из области компиляторных технологий.
- Последовательность лексем (лексический анализ).
- Абстрактное синтаксическое дерево (синтаксический анализ).
- Информация о типах (семантический анализ).
- Построение промежуточного представления, возможно, более высокоуровневого, чем в компиляторе.
- Построение модели программы, описывающей потоки управления и данных:
  - граф потока управления (control flow graph);
  - граф вызовов (call graph);
  - граф зависимостей по данным (dependence graph).

Граф потока управления

- Как правило, граф потока управления строится для каждой функции отдельно.
- Анализ по ГПУ без графа вызовов — внутрипроцедурный.
- Вершиной может являться базовый блок или отдельный оператор (тогда вершин больше).

```
int n = 10;
int f = 1;

while (n > 0) {
    f = f * n;
    n = n - 1;
}

res = f;
```

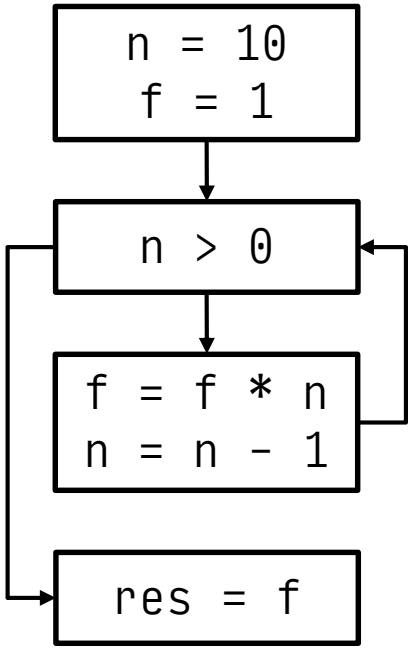

Граф вызовов

- Анализ, учитывающий граф вызовов, — межпроцедурный.
- Трудность: какие рёбра следует провести для вызова по указателю?
- Требуется анализ значений указателей.

```
int
a(int x)
{
    if (x) {
        b(1);
    } else {
        c();
    }
}

int
b(int y)
{
    if (y) {
        c(); b(0);
    } else {
        c();
    }
}

void
c(void) { }
```

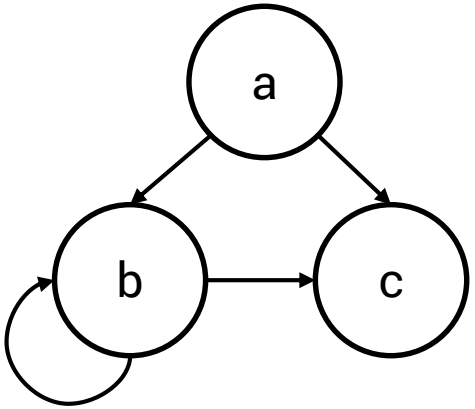

Граф зависимостей

- Оператор *s* зависит по данным от оператора *t*, если существует путь от *t* к *s* и значение какой-либо переменной определяется в *t* и используется в *s* (DU-зависимость).
- Отношение «зависит по данным» может быть представлено в виде графа, в вершинах которого — операторы, а рёбра соответствуют наличию зависимости.
- На практике помимо DU-зависимостей интересны также:
  - чтение-запись (UD-зависимость);
  - запись-запись (DD-зависимость).
- В графе зависимостей также представлены зависимости по управлению.

Граф зависимостей

Какие рёбра в данном примере?

```
int n = 10;
int f = 1;

while (n > 0) {
    f = f * n;
    n = n - 1;
}

res = f;
```

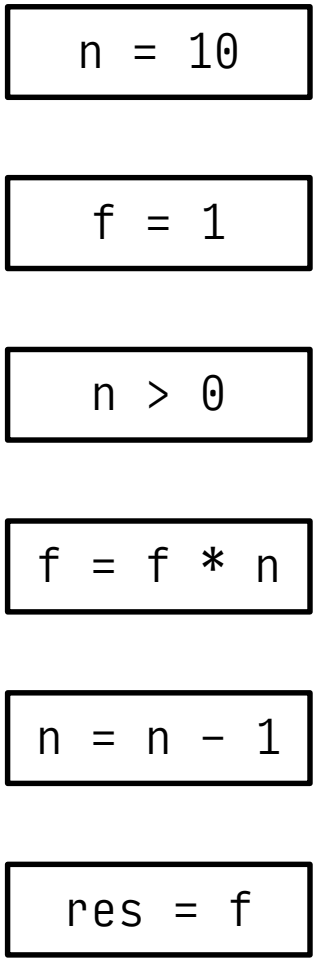

Граф указателей

```
r = malloc(…);
p->f = r;
t = malloc(…);
if (…) { q = p };
r->f = t;
```

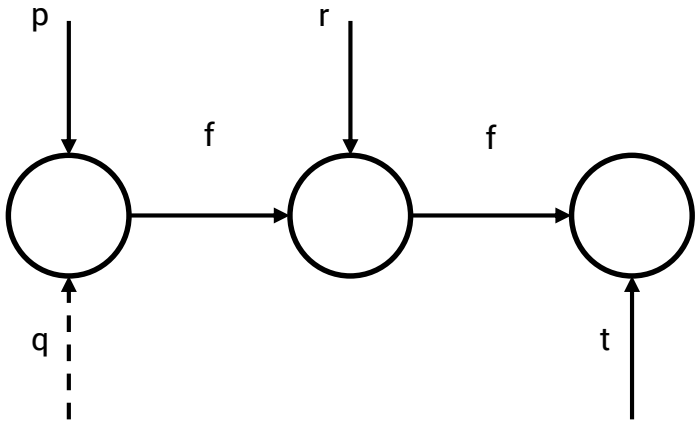

Связь между анализом потоков управления и данных

- Внутрипроцедурный анализ потока управления (ГПУ) обеспечивает:
  - определение последовательности анализируемых конструкций.
- Межпроцедурный анализ потока управления (ГВ) обеспечивает:
  - передачу параметров в вызываемые функции и возвращаемого значения в точку возврата.
- Анализ потока данных обеспечивает (ГЗ) обеспечивает:
  - определение возможных значений переменных во всех точках программы;
  - определение недостижимых переходов;
  - определение возможных целей вызова функции по указателю.

Определение недостижимых переходов

```
main() {
   a = b + 1;
   if (a < b)
   {
      c = 1;
   }
   else
   {
      c = 2;
   }
}
```

Анализ потока данных

всегда верно,
что a > b

Анализ потока управления

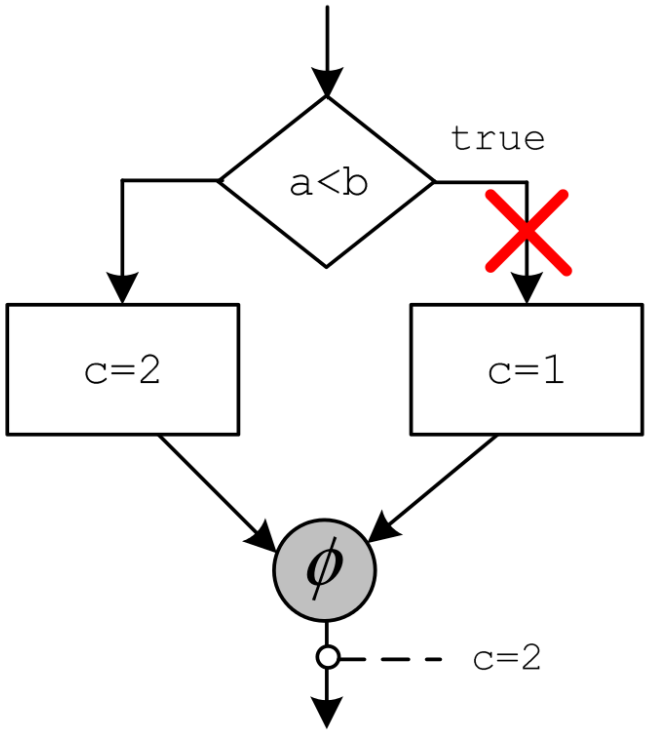

Вызов функции через указатель

```
main() {
     pf = &f;
     ...
     a = a + 1;
     y = *pf(a);
     ...
}

int f(int x) {
     return x*x;
}
```

Анализ потока данных

pf -> f

Анализ потока управления

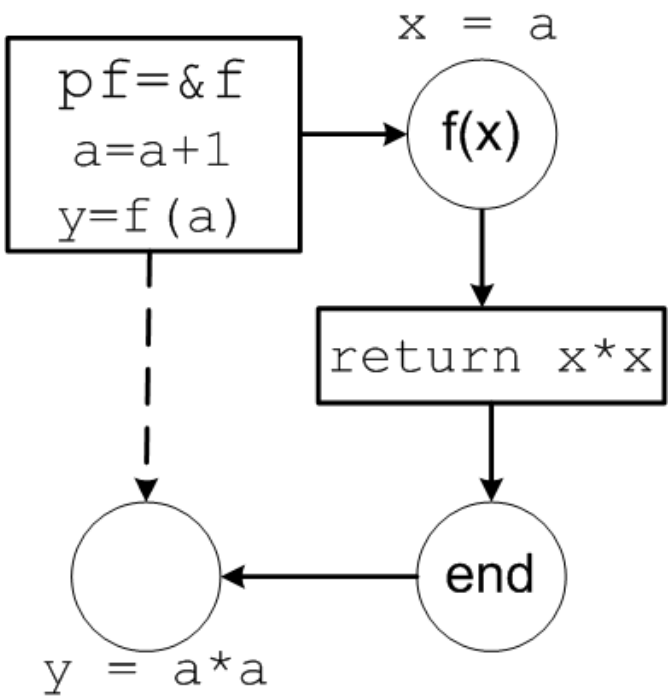

Алиасы (псевдонимы)

- Набор различных выражений, которые обозначают одну и ту же переменную.
- Примеры конструкций, порождающих алиасы:
  - использование указателей, в частности, указателей на функции;
  - элементы массивов (индексные выражения);
  - объединения (union).
- Алиасы представляют проблему для анализа потоков данных и управления:
  - состояние какой переменной меняется в инструкции?
  - какая функция (набор функций) будет (или может быть) вызвана по указателю в данной точке вызова?
- Анализ алиасов (в частности, анализ указателей).

Чувствительность анализа

- Чувствительность к пути – способность анализа различать разные пути в программе

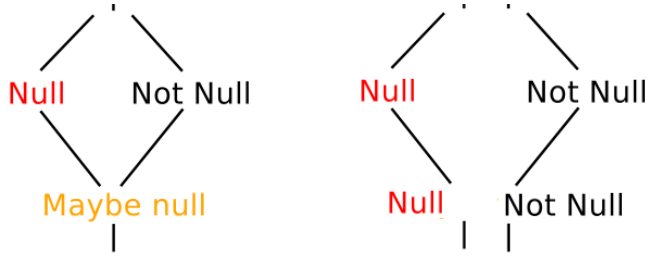

- Чувствительность к потоку – способность анализа различать порядок следования инструкций

“Указатель p может указывать на x”
“Указатель p может указывать на x после инструкции I”

- Чувствительность к контексту – способность анализа различать разные вызовы одной функции

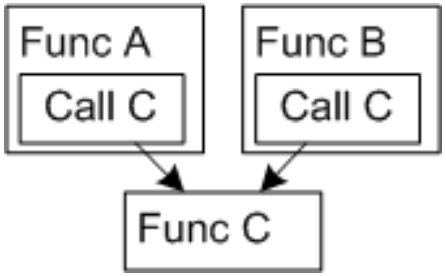

- Внутрипроцедурность/Межпроцедурность – анализ потоков данных только внутри одной функции/между функциями

0403

КЛАССЫ ОБНАРУЖИВАЕМЫХ ОШИБОК - ПУТЬ РАСПРОСТРАНЕНИЯ ОШИБКИ

Классы обнаруживаемых ошибок

- Ошибки работы с ресурсами:
  - утечки памяти или других ресурсов;
  - неверная последовательность операций (например, двойное освобождение);
  - ошибки при работе с многопоточными примитивами.
- Ошибки ввода/вывода:
  - форматная строка.
- Арифметические ошибки:
  - деление на ноль.
- Использование неинициализированных значений.
- Ошибки работы с памятью:
  - разыменование нулевого указателя;
  - выход за границы буфера.

Пример утечки памяти

```
int f(void)
{
    int *p = malloc(SIZE);
    // ...
    return 0;
}
```

Утечка динамической памяти при выходе из функции

```
int f(void)
{
    int *p = malloc(SIZE);
    int *q = malloc(SIZE);
    // ...
    if (flag) p = q;
    // ...
}
```

Утечка динамической памяти при потере указателя

Пример использования неинициализированных переменных

```
int f(void)
{
    int i;
    if (i > 0) {
        // ...
    }
    // ...
}
```

Использование неинициализированной переменной

```
int f(_Bool flag)
{
    int *p;
    if (flag) *p = 0;
    // ...
}
```

Разыменование неинициализированного указателя

Пример ошибок ввода-вывода

```
int f(void)
{
    char value[50];
    scanf(“%49s”, value);
    // ...
    printf(value);
    return 0;
}
```

Использование внешних данных в качестве форматной строки

```
int f(void)
{
    char *s = malloc(10);
    // ...
    gets(s);
}
```

Использование опасных функций

Пример ошибок ввода/вывода

```
int f(){
  char value[50];
  scanf(“%49s”, value)
  …
  printf(value);
  return 0;
}
```

Использование внешних данных в качестве форматной строки

```
int f(){
   char* s = malloc(10);
   …
   gets(s);
}
```

Использование опасных функций ввода

Путь распространения ошибки

- Цель обнаружения ошибки — её устранение.
- Ошибка обнаруживается в месте её проявления в программе (выполнение некорректного действия).
- Исправление может требоваться в другом месте.
- Путь распространения ошибки — поток данных в программе, приведший к ошибке, делится на 3 части:
  - источник (source) — место инициализации переменных, значения которых привели к ошибке;
  - распространение (propagation) — инструкции, участвовавшие в обработке/передаче значений, которые привели к ошибке;
  - место проявления ошибки (sink) — инструкция, приводящая к ошибке.

Путь распространения ошибки. Пример 1.

```
int f(){
   int i;          - источник
   …
   if(i > 0)       - проявление
   {
       …
   }
   …
}
```

Путь ошибки «Использование неинициализированной переменной»

Путь распространения ошибки. Пример 2.

```
int f(bool flag){
   char *buf;
   int j;
   int i = 4;              - источник 1
   if(flag){
       buf = malloc(10);   - источник 2
   }
   else{
       buf = malloc(20);   - источник 3
   }
   j = i + 10;             - распространение
   buf[j] = 0;             - проявление
}
```

Путь ошибки
«Переполнение буфера»

0404

АЛГОРИТМ ПОИСКА ОШИБОК - ОГРАНИЧЕНИЯ АНАЛИЗА

Общая схема поиска ошибок

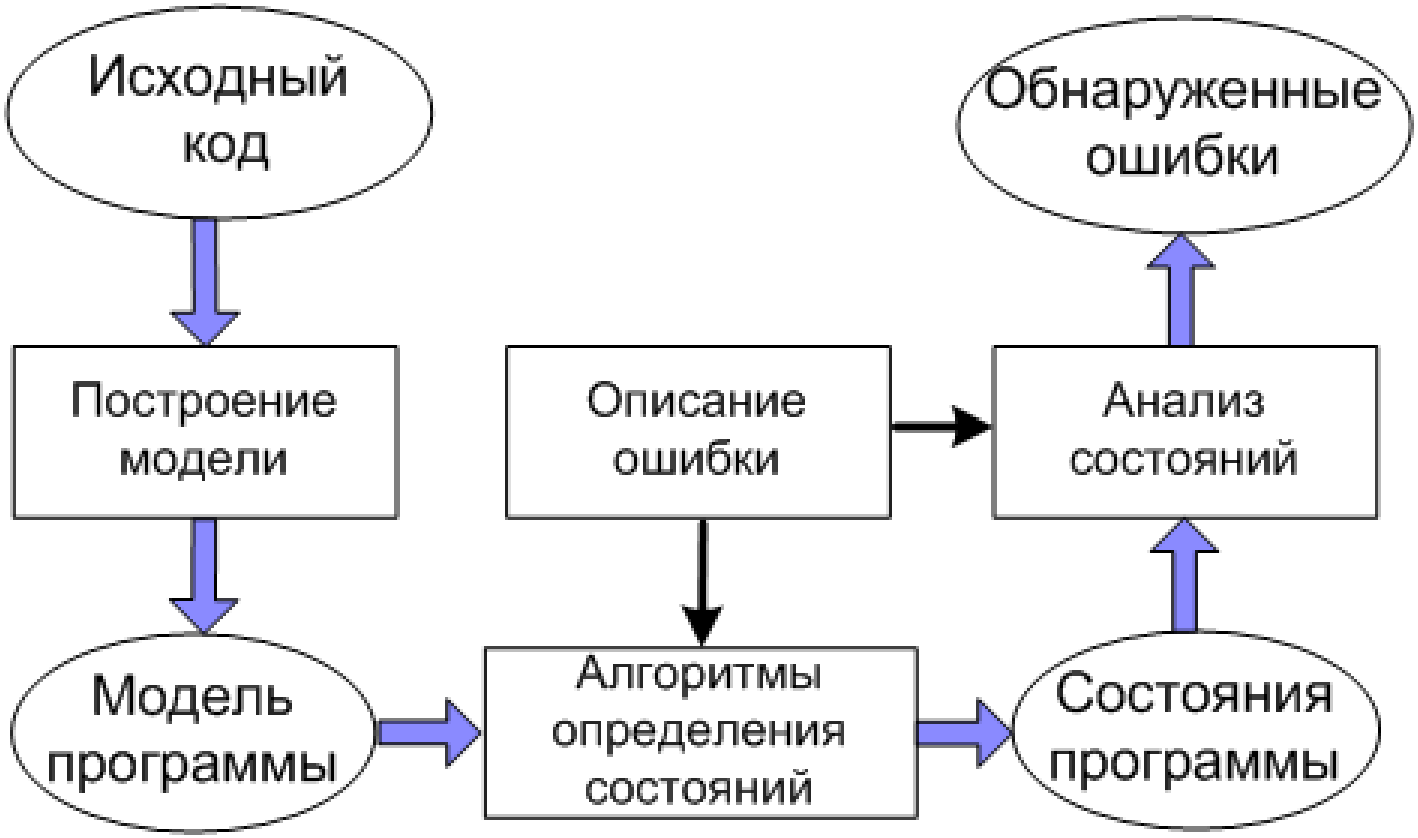

Описание ошибки

- Каждый тип ошибки характеризуется:
  - Список источников – инструкции, порождающие значения, впоследствии приводящие к ошибке
  - Список правил – описание того, как различные инструкции влияют на значение, приводящее к ошибке
  - Список инструкции приводящих к проявлению ошибки и условия её возникновения
- Пример описания ошибки «разыменование нулевого указателя»:
  - Источники – операции инициализации указателя
  - Правила – операции присвоения
  - Проявление ошибки – разыменование указателя, при условии, что указатель может быть равен нулю.

Анализ программ на основе состояний

- Определяются состояния объектов программы во всех точках программы (между выполнением инструкций)
- Состояние программы – возможные состояния всех объектов, видимых в данной точке программы: S_l = {<объект, состояние>}
- Различные типы объектов программы: переменные, указатели, файлы, …
- Для разных типов объектов – разные состояния:
  - Переменные – возможные значения
  - Указатели – равенство нулю, объекты на которые может указывать
  - Файл – открыт/закрыт на чтение/запись

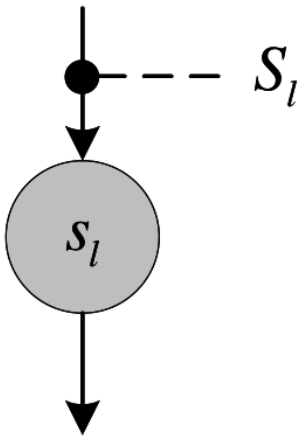

Алгоритмы определения состояний

- Для анализа состояний разных объектов используются различные алгоритмы:
  - Алгоритм анализа значений
  - Алгоритм анализа указателей
  - Алгоритм ресурсного анализа
- Алгоритмы анализа представлены в виде правил для конструкций программы
- Каждое правило формирует уравнение, над состояниями объектов программы

```
Rule(Sl)→Eq(Sl,Sl + 1)
```

- Строится система уравнений, решение которой даёт состояния объектов программы во всех точках

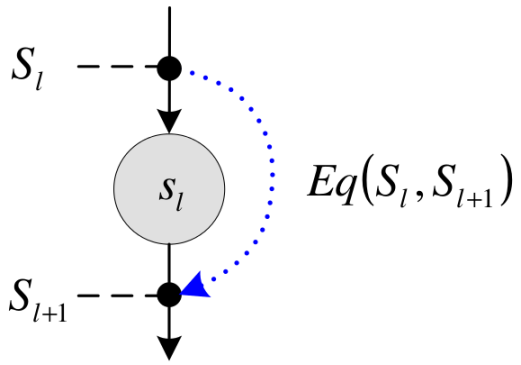

Алгоритм поиска ошибки

1. Найти в модели программы инструкции-источники ошибки.
2. Проинициализировать состояния объектов в соответствии с классом ошибки.
3. Распространить состояния объектов по графу потока управления программы с учётом графа вызовов в соответствии с правилами ошибки – получить состояния в каждой точке программы .
4. Найти в модели программы инструкции, которые могут приводить к проявлению ошибки.
5. Проверить в них состояние программы в соответствии с условиями возникновения ошибки.

Преимущества статического анализа

- Раннее обнаружение ошибок — во время разработки.
- Код при этом может не собираться и не запускаться.
- Полное покрытие кода.
- Не требуется задавать тестовые входные данные.
- Лучше проверяет участки кода, сложные для тестирования (обработка ошибок).

- Однако:
  - статический анализ не является заменой тестирования (не проверяет логику программ).

Ограничения статического анализа

- Отсутствие знаний о входных значениях (неопределённые значения переменных).
- «Экспоненциальный рост» числа путей в программе.
- Большая длина отдельных путей в программе (циклы, рекурсивные вызовы).
- Сложность анализа циклов и рекурсивных вызовов (сколько раз выполнялись?).
- Проблема «алиасов».
- Возможность отсутствия части кода программы (библиотек).
- Большой объём данных описывающих состояния программы (возможные значения).

Возможные упрощения

- Сокращение числа анализируемых путей выполнения:
  - совместный анализ путей выполнения программы.
- Сокращение длины анализируемых путей:
  - ограничение на глубину стека вызовов;
  - ограничение на число итераций при анализе циклов.
- Сокращение объёма данных, связанных с путями:
  - сокращение количества анализируемых объектов, например представление массива одним объектом;
  - компактное хранение состояний объектов: вместо { 1, 2, …,10 } – интервал [1, 10].
- Возможность аннотации внешних функций в виде некоторой суммы их влияния на данные:
  - «OpenFile() возвращает созданный объект типа файл или 0».

Автоматизация

- Уровень автоматизации:
  - количество входных данных и действий, требуемых от пользователя перед началом анализа;
  - возможность предоставления дополнительных данных для уточнения анализа;
  - дополнительная постобработка выдаваемых ошибок.
- Входные данные и действия:
  - необходимость аннотации внешних функций;
  - необходимость создания специальной сборки проекта.
- Уточнение:
  - дополнительная аннотация кода.
- Постобработка выдаваемых ошибок:
  - возможность ранжирования выдаваемых ошибок по серьёзности, вероятности истинности и т.д.;
  - возможности по проверке истинности выданных ошибок.

Литература к лекции

Основные источники

1. Flemming Nielson, Hanne R. Nielson, Chris Hankin. Principles of Program Analysis / Springer, 1999.
2. Al Bessey, Ken Block, Ben Chelf, Andy Chou, Bryan Fulton, Seth Hallem, Charles Henri-Gros, Asya Kamsky, Scott McPeak, Dawson Engler. A Few Billion Lines of Code Later: Using Static Analysis to Find Bugs in the Real World // Comunications of the ACM, 2010, vol. 53, no. 2, pp. 66-75.
3. William R. Bush, Jonathan D. Pincus, David J. Sielaff. A Static Analyzer for Finding Dynamic Programming Errors // Software — Practice and Experience, 2000, vol. 30, issue 7, pp. 775-802.
4. Альфред В. Ахо, Моника С. Лам, Рави Сети, Джеффри Д. Ульман. Компиляторы. Принципы, технологии и инструментарий / Вильямс, 2015.