

О некоторых ограничениях полносистемного анализа помеченных данных

*М.А. Климушенкова, М.Г. Бакулин, В.А. Падарян,
П.М. Довгалюк, Н.И. Фурсова, И.А. Васильев*

Анализ помеченных данных

Анализ помеченных данных - метод исследования программы путём внесения пометок и отслеживания их распространения по потокам данных

- Отслеживание данных, полученных из недоверенных источников. Если они оказывают непосредственное влияние на счетчик инструкций и исполняемый код, то такие данные следует признать небезопасными
- Отслеживание чувствительных данных. Обнаружение «утечек» данных или их несанкционированного использования

Анализ помеченных данных

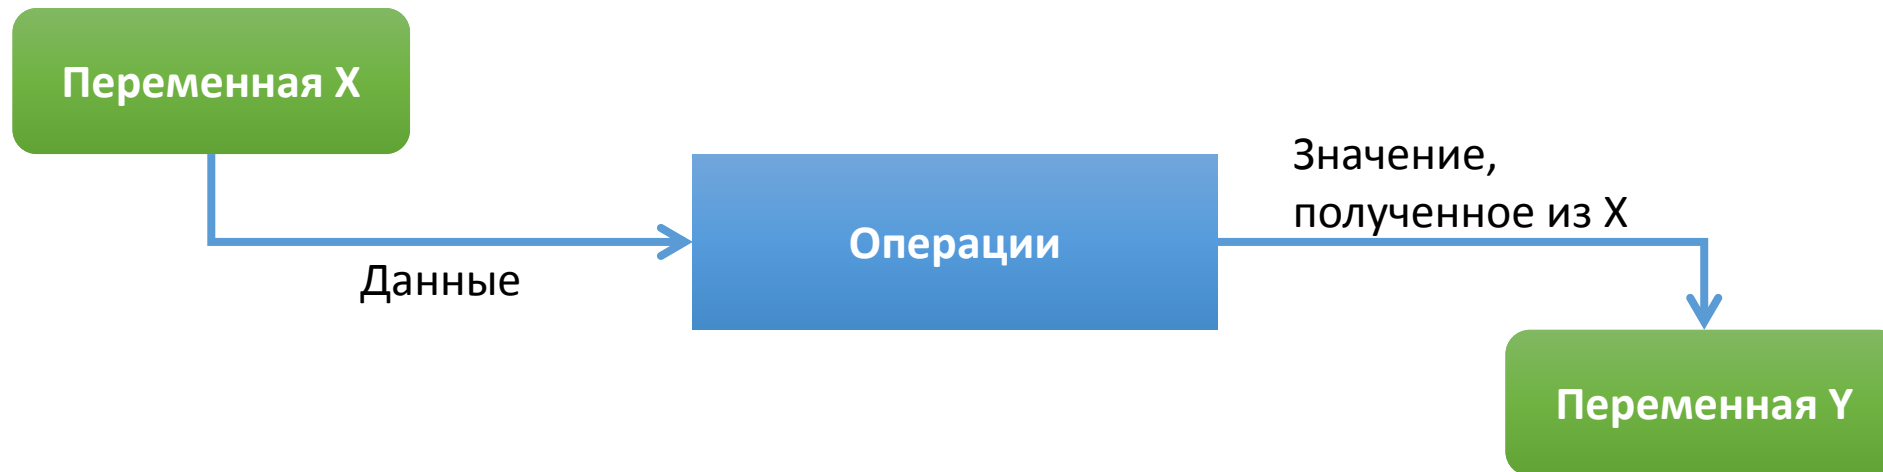
Пометки



Если источник значения переменной X является недоверенным, то переменная X помечается

Анализ помеченных данных

Поток данных



Операция или последовательность операций, которые используют значение переменной X, чтобы получить значение для переменной Y, порождает поток от X к Y

Анализ помеченных данных

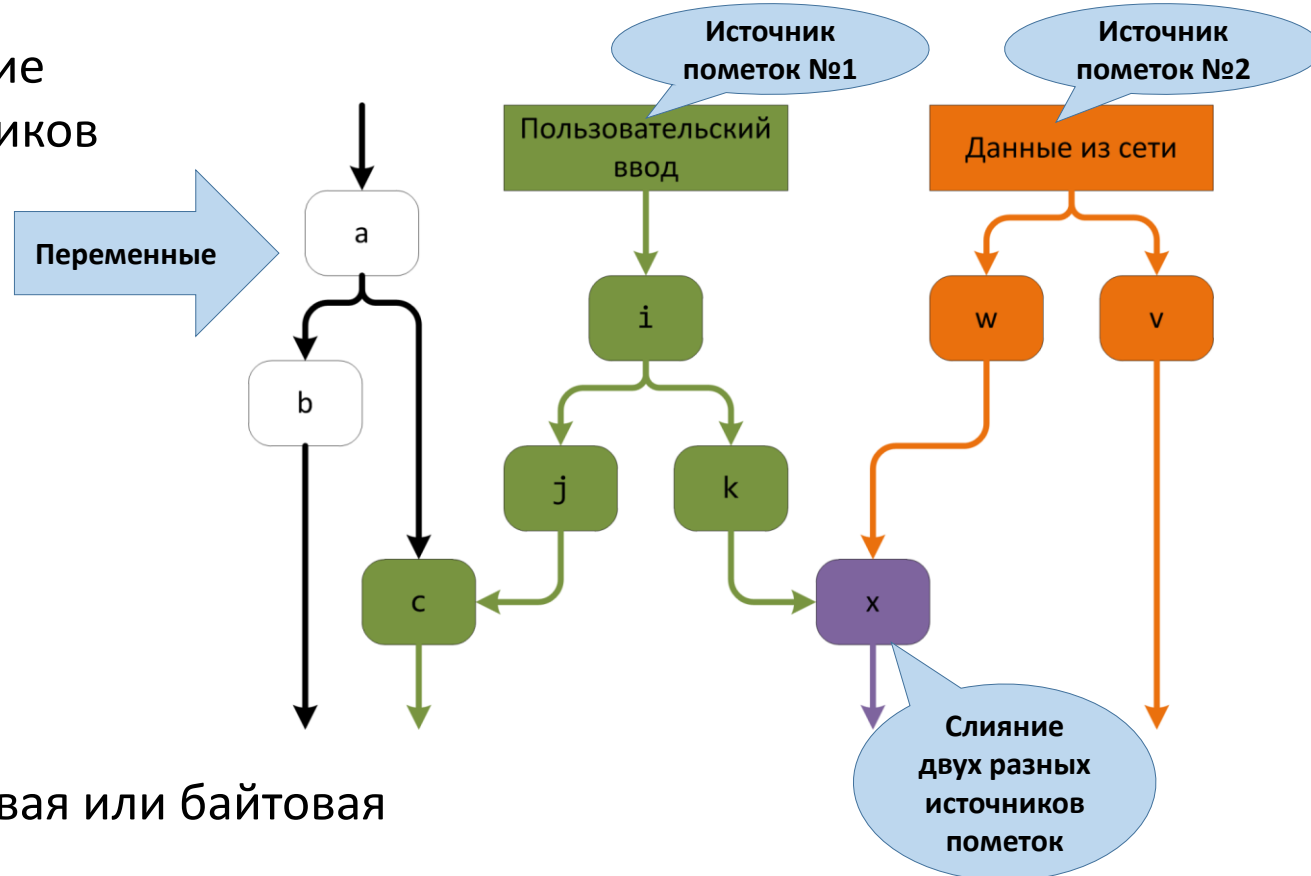
Поток данных




Если операция использует помеченное значение переменной X, чтобы получить значение для переменной Y, то значение X становится помеченным

Распространение меток

Одновременное продвижение
пометок от разных источников



Гранулярность пометок: битовая или байтовая



Анализ процесса vs анализ системы

- Анализ отдельного процесса
 - Метки не распространяются через код ядра
 - Необходим дополнительный анализ библиотечных функций
 - libdft, Dytan, Minemu
- Полносистемный анализ
 - Существенное замедление
 - TaintBochs, Timescope, DECAF, ARGOS, PANDA

Известные работы

1. PANDA, 2013, Georgia Tech, MIT Lincoln Laboratory
 - Инструмент основан на QEMU 1.0.1
 - Автоматическая трансляция вспомогательных функций и TCG-кода в байткод LLVM, на уровне которого происходит анализ
 - Низкая скорость работы
2. DECAF, 2014, Syracuse University
 - Основан на QEMU 1.0 и BitBlaze
 - Пометки распространяются при помощи инструментального TCG-кода и модифицированных вспомогательных функций
3. ARGOS, 2008, Vrije Universiteit Amsterdam
 - Последняя версия портирована на QEMU 1.1
 - Реализован только для архитектуры i386
 - Предназначен для использования как т.н. honeypot, все входящие сетевые данные автоматически помечаются

Реализация полносистемного анализа

- Где хранить пометки?
- Когда добавлять пометки?
- Как распространять пометки?
- Как обнаружить недопустимую ситуацию?

Реализация полносистемного анализа в QEMU

- Где хранить пометки?
 - Теневая память
 - Теневые регистры
- Когда добавлять пометки?
 - Пометка сетевого трафика
 - Пометка областей памяти или регистров
- Как распространять пометки?
 - Добавление инструкций, продвигающих пометки в промежуточное TCG представление. Инструкции добавляются если пометок нет
 - Изменение вспомогательных функций
- Как обнаружить недопустимую ситуацию?
 - Помеченный счетчик инструкций

Недостаточная помеченность

- Помечено меньше данных, чем необходимо согласно логике работы кода
- Причины:
 - Адресные зависимости
add esi, eax
mov [esi], 0x2A
 - Зависимости по управлению
if (x == 42)
y = 0;
else
y = 1;

Избыточная помеченность

- Помечено больше данных, чем необходимо согласно логике работы кода
- Причины:
 - Операции с константным результатом (XOR)
 - Односторонние функции (хэш)
 - Адресные зависимости

```
add esi, eax
cmp esi, 6
ja LN7
jmp LN11[esi*4]
```

Особенности реализации

- Блочная память
- Регистры устройств
- DMA транзакции
- USB-устройства
- Распространение пометок через инструкции FPU, MMX, SSE

DESAF: Ложноположительные результаты

Причины:

- Отсутствие обработки DMA транзакций
- Отсутствие корректной работы с синхронными, асинхронными прерываниями и системными вызовами

Результат:

- Количество ложноположительных срабатываний снизилось с 80% до 25%

Трудности полносистемного анализа

- Теоретические
 - Адресные зависимости
 - Зависимости по управлению
 - Константные и односторонние функции
- Практические
 - Недетерминированная работа симулятора
 - Работа с устройствами
 - DMA-транзакции
 - Обработка прерываний
 - Поддержка FPU, MMX, SSE