

# Анализ программ: эффективность и безопасность

Арутюн Аветисян  
[arut@ispras.ru](mailto:arut@ispras.ru)

# Вызов – обеспечение качества ПО

- Качество современных программных систем определяется тремя взаимосвязанными компонентами:
  - эффективность
  - **безопасность**
  - переносимость
- Обеспечение требуемого качества ПО связано с использованием ручного труда высококвалифицированных специалистов и является искусством (существенное увеличение стоимости и сроков разработки ПО)

# Безопасность

В настоящее время уровень информационной безопасности в значительной мере определяется наличием **ошибок в ПО и их эксплуатируемостью**

Ошибки\* в исполняемом коде могут приводить к:

- Потере стабильности работы программы
- Уязвимостям защиты (security vulnerability) – потенциальная возможность обойти средства разграничения прав доступа программы или ОС, в которой программа выполняется, создание эксплойта

\*Границы между ошибками программиста, закладками, НДВ размыты

# Ошибки. Примеры.

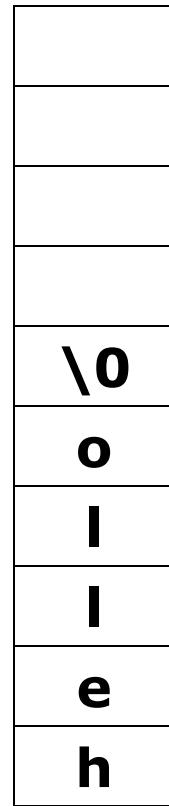
- Heartbleed (OpenSSL) – чтение памяти на сервере или клиенте. Конец 2011- апрель 2014. На момент публикации уязвимости было подвержено около 0.5 млн сайтов (CVE-2014-0160)
- Клиент OpenSSH версии от 5.4 до 7.1, утечка приватного ключа клиента, возможна атака MITM при первом подключении к новой системе (CVE-2016-0777). Трудно сказать ошибка или закладка.
- Ядро Linux от 3.8 до 4.5 - локальный пользователь может получить права суперпользователя (CVE-2016-0728)
- FreeBSD версии 9.3, 10.1 и 10.2 , отказ в обслуживании, повышение привилегий, раскрытие данных (CVE-2016-1881,CVE-2016-1880, CVE-2016-1879, CVE-2016-1882, CVE-2015-5677)
- Apple IOS 6.0-9.2 и OSX 10.0-10.11.2, повышение привилегий, выполнение произвольного кода, отказ в обслуживании (CVE-2016-1722)

# Пример (переполнение буфера)

```
f(char * p)
{
    char s[6];
    strcpy(s,p);
}
main1 () ←
{
    f("hello");
}
main2 ()
{
    f("privet");
}
```

Стек после выполнения функции f, вызванной из main1

Адрес main1

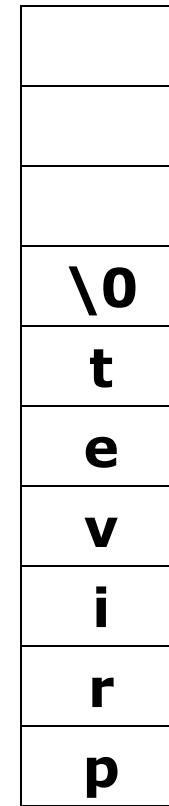


Стек после выполнения функции f, вызванной из main2

На место адреса main2 записали лишний байт

адрес возврата

массив s



В случае main2 адрес возврата перезапишется и управление будет передано не на main2, а на другой участок кода

## Пример (ошибки непроверенного ввода )

```
#include <stdio.h>
#include <stdlib.h>
int main(void)
{
    char buf[80], cmd[100];
    fgets(buf, sizeof(buf), stdin);
    snprintf(cmd, sizeof(cmd), "ls -l %s", buf);
    system(cmd);
    return 0;
}
```

Например: ls -l myfile ; rm -rf /

# Тенденции развития (I)

## □ Эскалация размеров и сложности

Система	Год	Размер ( $10^6$ LOC)
Дистрибутив Debian Sid	2016	>1166
Android 5	2014	>47
Android 6	2015	>39
Tizen 3	2015	>134
Linux Kernel 4.4	2016	>20

- Широкое использование Свободного ПО  
(одна ошибка тиражируется во многих продуктах, например,  
уязвимость в OpenSSL)
- Возрастание сложности среды разработки и сборки  
(например, компилятор может добавить уязвимость\*, которой  
нет в исходном коде)

\***memset (password, '\0', len);**  
**free (password);**

## Тенденции развития (II)

- Сервис-ориентированные центры обработки данных («облачные» инфраструктуры)
- Массовое внедрение мобильных платформ
- Массовое внедрение встроенных систем в физические объекты и их объединение в единую сеть – «Интернет вещей»

**Традиционные подходы защиты  
по периметру недостаточны**

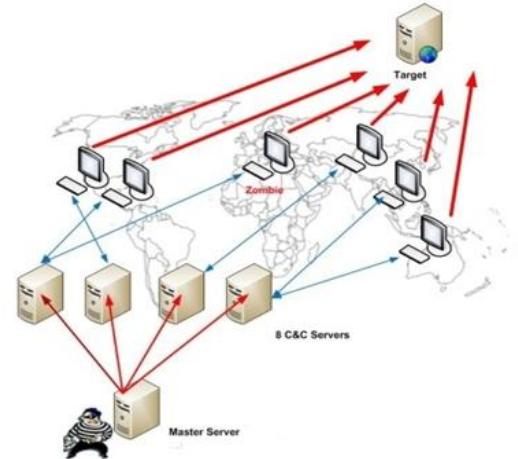
# Ошибки – существенный рост ущерба



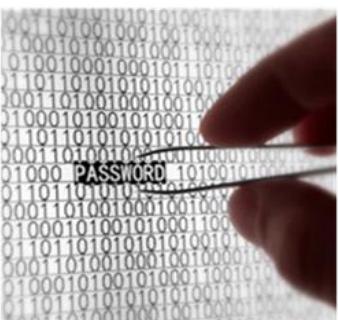
Аварии на  
критических  
объектах



Перехват  
управления



Бот-неты



Кража паролей



Уязвимости



Кража информации о  
кредитных картах

# Ошибки. Статистика

## □ Debian Linux:

- 1892 критических ошибки в текущем релизе
- исправлены 229
- ~ 140 программ содержат не исправленные CVE с 2010 по 2016 год

## □ Кластер из 100 узлов, тестирование заняло 28 дней машинного времени\* (проанализировано 37 тыс. программ из состава Debian Linux)

Сгенерировано 207 миллионов тестов

Зафиксировано  
2 606 506 падений

13 875 уникальных ошибок

152 перехвата управления

\*от авторов инструмента *Mayhem*, на Debian (David Brumley, Thanassis Avgerinos) [forallsecure.com/debian](http://forallsecure.com/debian)

# Подходы к выявлению ошибок в ПО

Традиционные: экспертиза (опыт и знания людей),  
тестирование – недостаточны

Одним из перспективных направлений исследований является развитие методов анализа программ (исходного и бинарного кода) и разработка соответствующих инструментов:

- Статический анализ
  - Поиск возможных дефектов в коде по некоторым шаблонам
- Динамический анализ
  - фаззинг, символьное выполнение, слайсинг, профилирование, ...
- Комбинированный анализ
  - Статический/динамический анализ с использованием (неполных) формальных моделей

# Дефект vs. Ошибка

Несоблюдение свойств модели некоторого уровня

## вычисления

- деление на ноль, защита памяти, ...

## язык программирования

- выход за пределы буфера, ...

## архитектура приложения

- состояние гонок, ...

## логика приложения

- политика безопасности – неправомерный доступ к данным

# Статический анализ исходного кода (I)

Активные исследования и разработки по созданию инструментов статического анализа (без выполнения кода) исходного кода, обеспечивающих автоматическое обнаружение дефектов в больших объемах кода (десятки миллионов строк) ведутся с середины 2000-х гг.

Разработан ряд стандартов (что искать?): *CWE, CWE/SANS Top 25, CERT, OWASP, DISA STIG, MISRA*

# Статический анализ исходного кода (II)

## Требования:

- Необходимость анализа систем в целом (межпроцедурный анализ, анализ указателей, анализ циклов, модель памяти)
- Анализ проекта размера Android и Tizen должен длиться 4-6 часов (ночная сборка)
- Поиск ошибок разного уровня критичности (от неверного форматирования, до переполнения буфера)
- Поддержка популярных языков программирования
- Высокий уровень истинных срабатываний

## Преимущества:

- Автоматический анализ многих путей исполнения одновременно
- Обнаружение дефектов, проявляющихся только на редких путях исполнения, или на необычных входных данных (которые могут быть установлены злоумышленником в процессе атаки)
- Возможность анализа на неполном наборе исходных файлов

# Виды статического анализа

Уровень работы анализа	Подходы	Инструменты
Лексический анализ	Поиск вызова заданных функций	ITS4, RATS, Flawfinder
Синтаксический анализ	Поиск шаблонов по AST	Lint, CppCheck, PVS-Studio
Семантический анализ	Анализ потока данных	<i>HP Fortify, FindBugs, PC-Lint, CodeSonar, Parasoft C/C++test</i>
	Символьное выполнение	Clang Static Analyzer, Coverity SAVE, Klockwork Insight, <b>Svace (ИСП РАН)</b>

# Svace – автоматическое обнаружение дефектов (I)

- Базируется на **модели** анализируемого кода (абстрактные ячейки памяти, их атрибуты и значения атрибутов, контексты инструкций), которая создается из промежуточного представления, генерируемого компилятором LLVM
- Выполняется статический анализ модели:
  - ✓ итерационный статический внутрипроцедурный анализ (анализ указателей, анализ интервалов, ...)
  - ✓ межпроцедурный анализ, управляемый графом вызовов
  - ✓ абстрактная интерпретация (символьное выполнение)
- Возможность анализа неполных программ (модулей, библиотек)
- Расширяемость набора подсистем поиска дефектов
- В настоящее время поддерживаются языки Си, Си++, Java, C#, находятся в разработке JavaScript и Python

# Svace – автоматическое обнаружение дефектов (II)

- Находит более 100 различных видов дефектов (переполнение буфера, разыменование нулевого указателя, проблемы синхронизации, нефильтрованный ввод, проблемы работы с памятью и др.)
- Нет ограничений на размер анализируемой программы: линейная масштабируемость (без потери качества анализа) – полный анализ Андроида (около 5 миллионов строк кода) за 3 часа
- Качество анализа и производительность сопоставимы с инструментами Coverity SAVE и Klockwork Insight
- Пользовательский интерфейс поддерживает распределенную работу с историей результатов анализа, как из командной строки, так и среды разработки Eclipse, в том числе, через web

# Svace – автоматическое обнаружение дефектов (III)

Тип предупреждения	Истинные срабатывания Svace
Переполнение буфера	60%
Работа с динамически выделенной памятью	50%
Разыменование NULL	70%
Испорченный ввод	70%
Неинициализированные данные	60%
Несоответствие типов возвращаемых значений	60%
Состояние гонки	90%
Передача по значению	100%
Другие (более 30)	50%

# Анализ бинарного кода

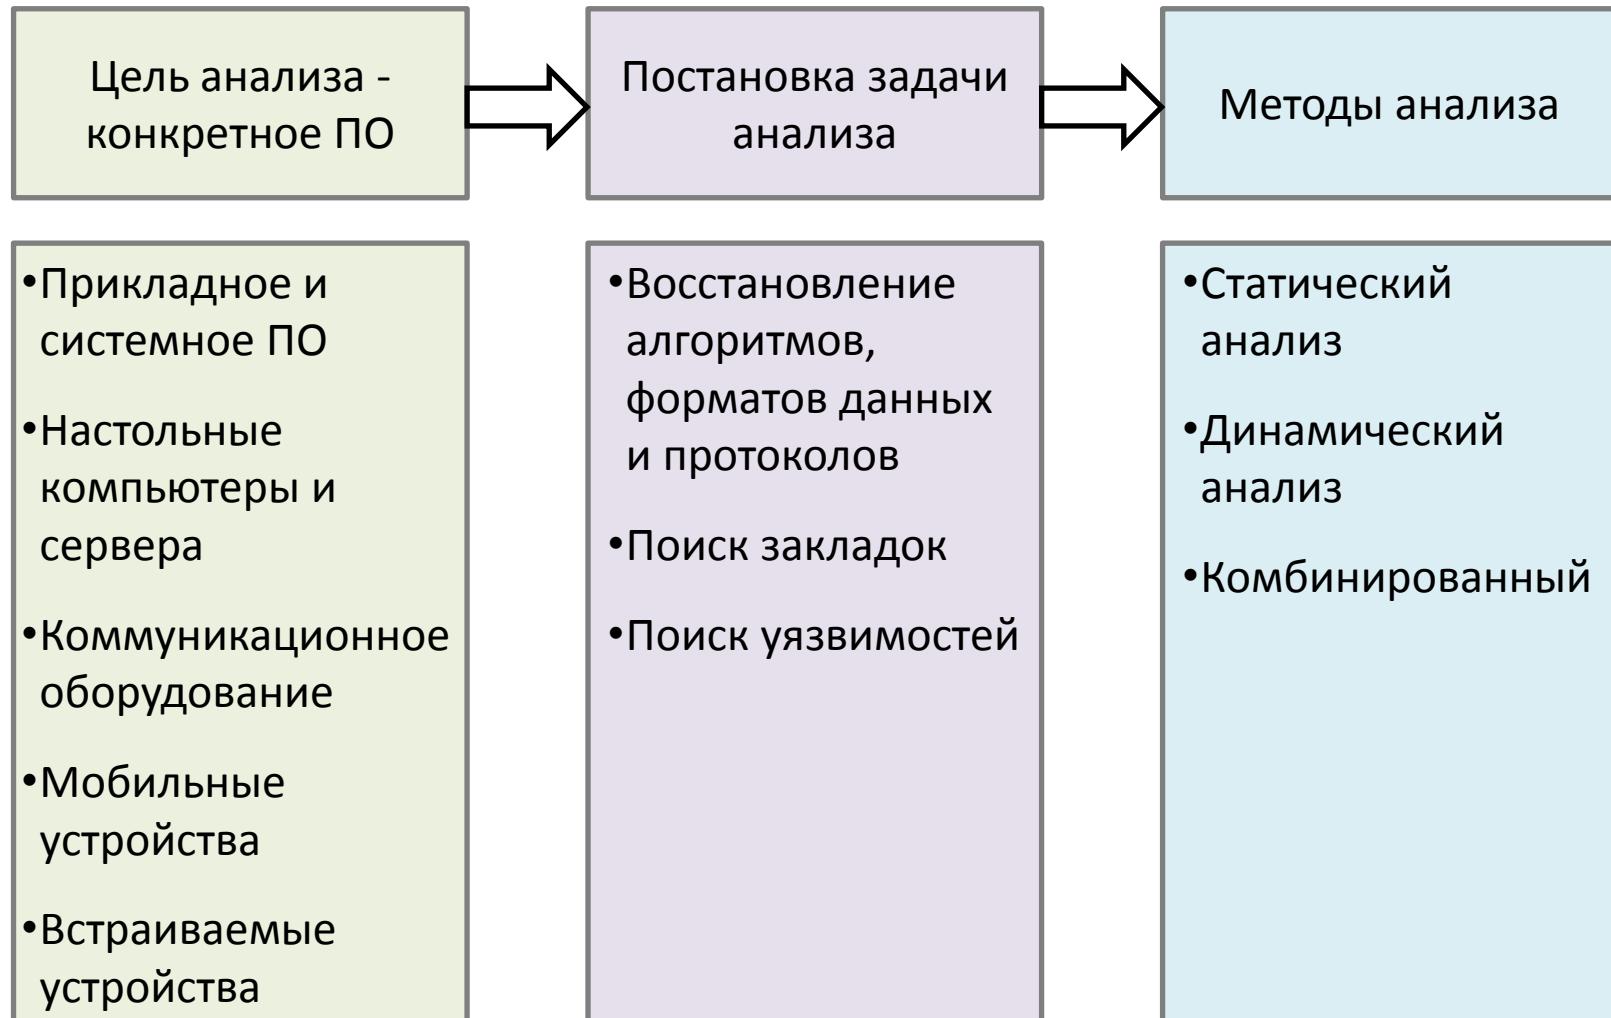
## Актуальность:

- Используется ПО, имеющееся только в бинарном коде, и/или «недостоверная» среда сборки
- Агрессивная оптимизация может вносить в код дефекты

## Средства:

- Статический анализ (*трудно применять к программам, снабженным средствами защиты от анализа*)
- Динамический или комбинированный анализ

# Цели и задачи анализа бинарного кода



# Динамический анализ бинарного кода – Avalanche

- Avalanche – технология автоматического динамического анализа (C/C++, Java), основанная на обходе возможных трасс выполнения и поиске ошибок на этих трассах:
  - ✓ Инstrumentация кода для получения трасс выполнения в виде набора ограничений (C/C++ - Valgrind, Java – BCEL)
  - ✓ Разрешение ограничений с помощью солвера (используется солвер на основе свободного ПО STP)
  - ✓ Построение новых наборов входных данных
  - ✓ Поиск ошибок, в том числе критических:
    - NPD, деление на ноль найдены в mono, llvm, libjpeg, swftools, xmllint и др.;
    - состояния гонки – в Browser и Mms (Android)
- Достоинство – генерация входных данных, на которых проявляется дефект
- Недостаток – ресурсоемкость

# Trex: среда комбинированного анализа бинарного кода (I)

- Базируется на **модели** анализируемого бинарного кода, получаемой на основе трасс и состоящей из модели кода в платформо-независимом представлении и модели областей памяти (регистров, стека, областей статических и глобальных данных) – регистровая RISC-машина
- Обеспечивает:
  - ✓ сбор и систематический анализ трасс (объединение трасс, динамический слайсинг и др.)
  - ✓ интеграцию с результатами статического анализа и др.
- Позволяет восстанавливать:
  - ✓ граф потока управления интересующих функций
  - ✓ структуры входных и выходных параметров
  - ✓ протоколы обмена данными и др.

# Trex: среда комбинированного анализа бинарного кода (II)

## Автоматизированный анализ в диалоговом режиме

- Навигация по графу зависимостей
- Восстановление форматов входных и выходных данных у блоков
  - Управление детализацией

IDA Pro

Дампы памяти с привязкой ко времени

Исполняемый код

Эмулятор с механизмом воспроизведения

Алгоритмы, структуры данных, значения переменных

Среда анализа

Итерационное построение блок-схемы

Граф зависимостей по данным

Архитектурно независимое промежуточное представление

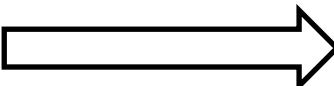
Восстановление функций

Граф потока управления

«Поколения» кода + интервалы времени, когда код неизменен

Набор трасс различного уровня

Предварительное восстановление без участия человека



## Trex: среда комбинированного анализа бинарного кода (III)

- Восстановлен алгоритм проверки лицензии SmartPlant License Manager 2010
- Восстановлен алгоритм распаковки кода и формат файла, в котором этот код содержится
- Выявлены механизмы внедрения вредоносного кода в операционную систему (вирус/руткит Trojan.Win32.Tdss.ajfl)

Пример выделения инструкций требуемого алгоритма:

	Трасса, содержащая код анализируемой программы в пользовательском режиме			Число инструкций после обработки
	Размер, МБ	Число шагов	Число инструкций в листинге	
VB v6.0	42	575 392	26 620	356
VB .NET	35	484 248	62 726	143

## Главные цели анализа ПО (технологии двойного назначения):

### □ Защита:

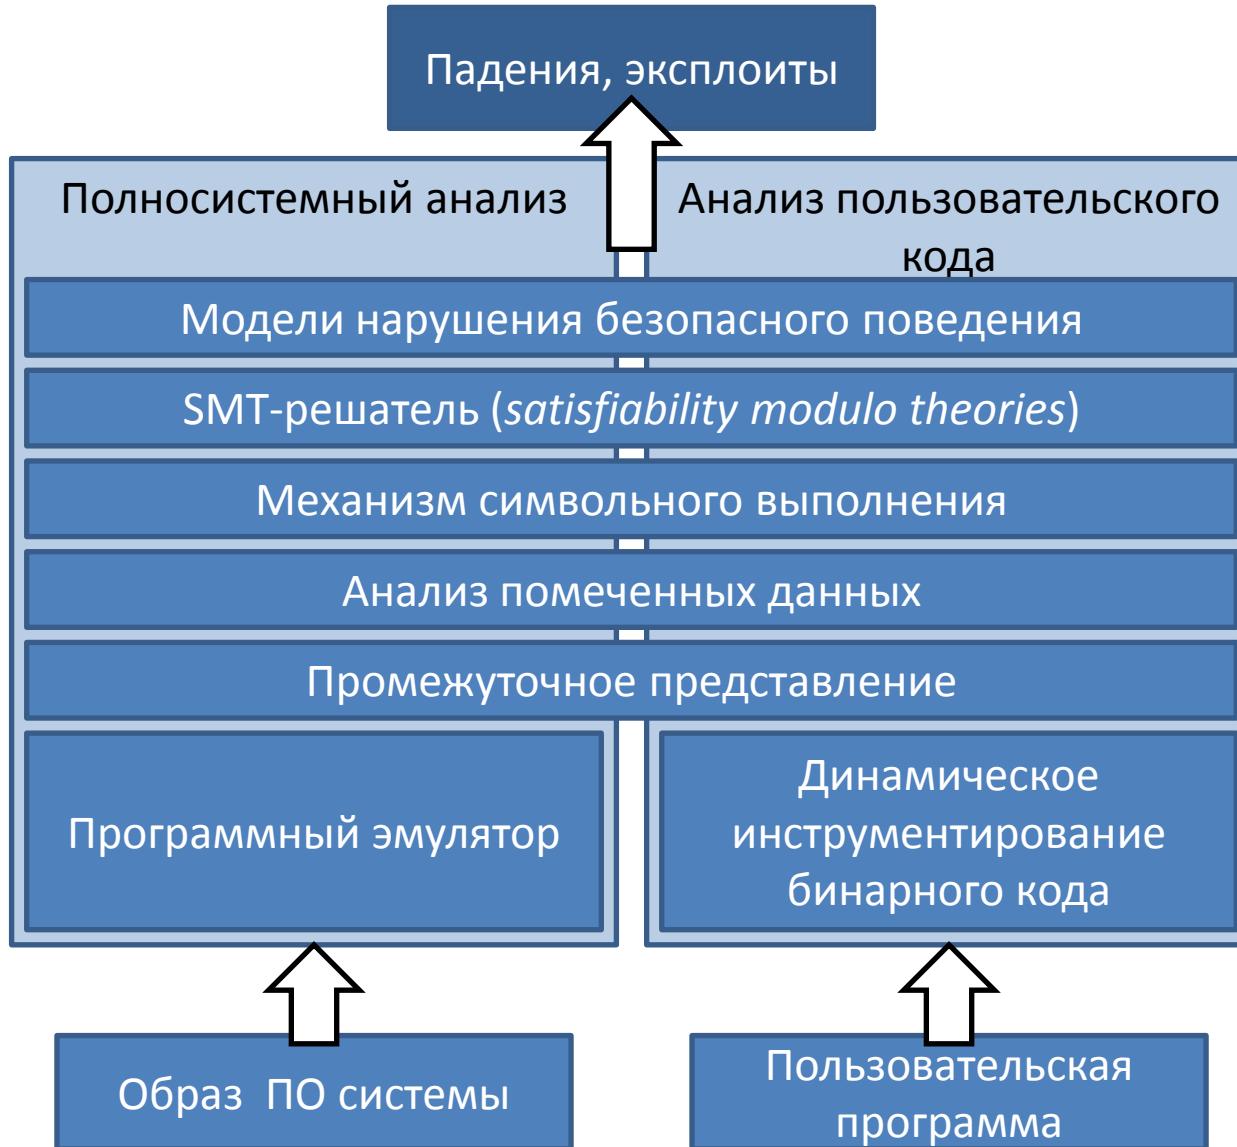
- найти и устраниить на этапах **разработки** и внедрения максимальное количество ошибок в исполняемом коде
- предотвратить эксплуатацию существующих ошибок или смягчить последствия их эксплуатации

### □ Нападение:

- Поиск уязвимостей и генерация эксплойта

# Перспективное направление (I)

## Автоматический поиск уязвимостей



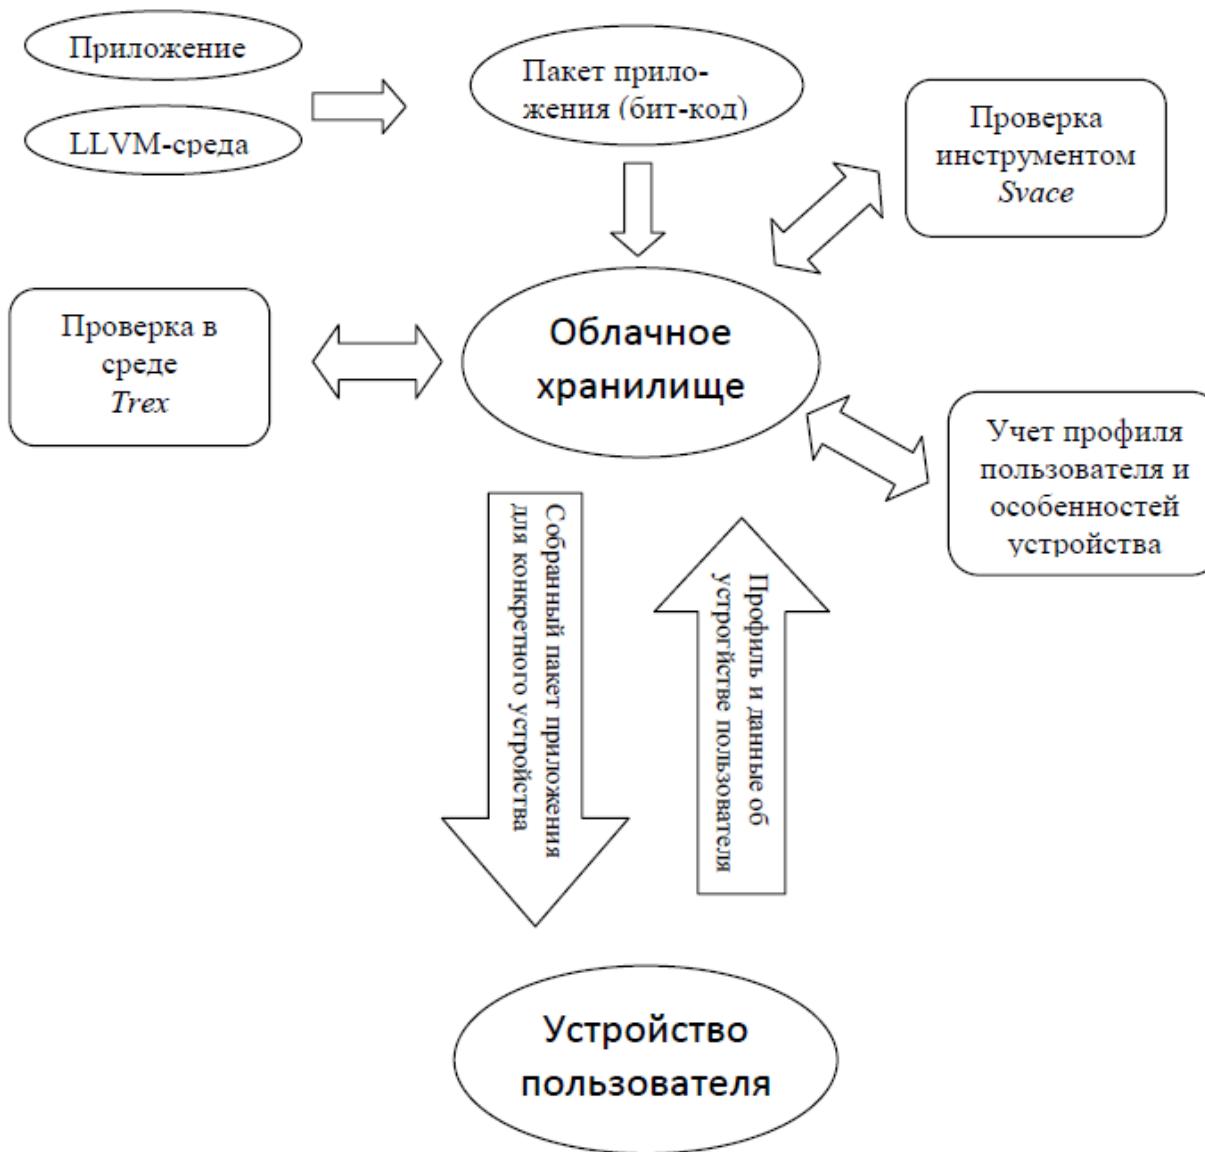
## Смешанные техники

- Статический анализ предоставляет список ошибок ПО и условия их возникновения
  - Исходный код
  - Бинарный код
- Динамический анализ подбирает данные для исполнения пути приводящего к ошибке
  - Фаззинг
  - Символьное выполнение

# Переносимость C/C++-приложений с сохранением эффективности

- Двухэтапная компиляция на основе LLVM:
  - ✓ распространение программы в биткоде LLVM
  - ✓ машинно-независимые оптимизации на стороне разработчика
  - ✓ машинно-зависимые оптимизации и оптимизации по профилю:  
в «облаке» (индивидуально для устройства)  
или статически/динамически на устройстве
  - ✓ возможность дополнительного статического анализа в облаке  
(выявление дефектов, обfuscация, ...)
- В настоящее время аналогичные работы ведутся в Apple

# «Облачное хранилище» приложений нового поколения



Спасибо