

# От идеи до внедрения Истории успеха ИСП РАН

Арутюн Аветисян  
arut@ispras.ru

02.12.2021

С.А. Лебедев



В.А. Мельников



БЭСМ-6 в музее науки Лондона



В.П. Иванников



Л.Н. Королёв



«Если мы глубже разберёмся в этом эпохальном советском суперкомпьютере, это позволит пересмотреть заявления времён холодной войны об отставании русской технологии, а также подтвердить или развеять мифы о технологическом совершенстве наших союзников».

*Doron Swade, senior curator of computing and information technology*

**2018: 70 лет IT\***  
**2019: 25 лет ИСП РАН**  
**2023: 75 лет IT\***

**\* в России и странах постсоветского пространства**



**2023: ИСП РАН проведёт COMputer, Software and Application Conference (COMPSAC) в Москве. Ключевая конференция IEEE CS, проводится ежегодно в течении 45 лет.**

# Цифровая экономика: приложения

- Непрерывный доступ в сеть интернет/интранет
- Киберфизические возможности
- Большая вычислительная сложность
- Умные устройства (дом, офис, завод)



Платформы «интернета вещей», искусственного интеллекта, ...


 Платформы хранения и обработки «больших» данных
 



 Облачные платформы
 




 Аппаратура
 


## Проблемы современного системного ПО:

1. Эскалация размеров (Astra Linux – более 150 миллионов строк кода).
2. Сложность среды разработки и сборки.
3. Отсутствие изолированных систем.

## Необходимые качества системного ПО:


- Эффективность
- Продуктивность
- Безопасность

# От фундаментальной\* идеи до продукта

## Примеры - важнейшие научные результаты РАН 2016-2020

\*Наукоемкие инновации основа долгосрочного конкурентоспособного развития ИСП РАН

# Svace. История разработки



## Swase в 2021 году – I

- В 2020 г. добавлены языки Kotlin и Go
- В 2020 г. улучшен анализ чувствительных данных для поиска критических уязвимостей
- Новый графический интерфейс работы с результатами анализа

## Сvace в 2021 году – II

- С 2009 г. внедряется в компании Samsung в рамках совместной лаборатории
  - С 2015 года внедрен в Samsung и ее дочерние компании как основной статический анализатор
  - 300+ млрд. строк кода проанализировано, 10+ тысяч пользователей
- С 2020 г. ведется внедрение в Huawei и доработка анализатора для программ компании в рамках совместной лаборатории по статическому анализу
- Используется в более чем 30 российских компаниях (Лаборатория Касперского, Код Безопасности, Постгресс...)

# Основные научные результаты

- Анализ потока данных на основе значений
- Контекстная чувствительность с использованием параметризованных резюме функций
- Чувствительность к путям на основе символического выполнения с объединением состояний
- **Алгоритмы *Svase* вошли в число лучших результатов РАН за 2016 г.**

Все в цифрах


700+ тыс. строк кода на 10 языках

600+ детекторов

50+ статей и регистраций программ

5 кандидатских и 2 докторских  
диссертации

# Среда анализа бинарного кода ТРАЛ



- Среда ТРАЛ включена в важнейшие результаты РАН за 2019 год

# Трал. Корни

- Начало проектной работы – лето 2007
- Отдел компиляторных технологий ИСП РАН
- Опыт разработки
  - Среда ParJava
  - Статический анализатор Svase
  - Портирование сложных систем на другие ОС и процессорные архитектуры
  - Разработка специализированных программных инструментов

Трал

50+ статей и регистраций программ

7 кандидатских и 1 докторская  
диссертация

# Инструменты жизненного цикла разработки безопасного ПО

- Статический анализ – одна из технологий, нужная для инструментальной поддержки жизненного цикла ПО
- Методы и алгоритмы, вошедшие в *Svace*, были дополнены методами динамического анализа (*Crusher*, *ИСП Фаззер*, *Sydr*, *Трал*), статического анализа бинарного кода (*Binside*), методами диверсификации и обфускации, безопасным компилятором на основе *GCC*
- Разрабатываются **ГОСТы** по применению статического и динамического анализа в практическом жизненном цикле безопасного ПО

# Лаборатория «Системного программирования» в Великом Новгороде

- Открыта в 2010 году
  - Численность на момент открытия – 4 человека
  - 2021 год – 12 человек
- Программный эмулятор как средство контролируемого выполнения
  - Базовое средство – QEMU
  - Детерминированное воспроизведение
    - В 2015 году патчи приняты сообществом QEMU, лаборатория поддерживает механизм воспроизведения в официальном дистрибутиве эмулятора
  - Интроспекция виртуальной машины
  - Обратная отладка
  - Полносистемная отладка без поддержки со стороны гостевой ОС
  - Платформа динамического анализа



# Лаборатория «Безопасное программное обеспечение» в Орле


- Открыта в 2019 году
  - Численность на момент открытия – 4 человека
  - 2021 год – 9 человек
- Технологии разработки безопасного ПО
  - Практические задачи аудита безопасности
  - Внедрение инструментов анализа кода в учебный процесс
- Разработка тестового ПО для оценки программных инструментов
- Стеганография
- Анализ сетевого трафика



# Учебная деятельность

- Архитектура ЭВМ и язык ассемблера
  - 1ый курс ВМК МГУ, часть сквозного курса программирования
- Информационная безопасность и анализ кода (Анализ кода и надежность программ)
  - Магистратура ВМК МГУ
- Информационная безопасность и компьютерные сети
  - Магистратуры ВМК МГУ, ФУПМ МФТИ, ФКН ВШЭ
- Проведение курсов повышения квалификации, в том числе – участие в совместных курсах с ФСТЭК России

# Платформа Talisman



- Накопление знаний о предметной области
  - Построение баз знаний
- Создание мониторинговых систем
  - Мониторинг репутации персон и организаций
  - Выявление неявных информационных кампаний
- Конкурентная разведка
  - Поиск информации об объектах в открытых источниках
  - Выявление неявных взаимосвязей между объектами
  - Интеграция открытой и закрытой информации

# Анализ социальных сетей

## Вызовы

1. Big Data: Большой объем связанной между собой информации
2. Специфичный язык
  - Сленг,
  - Внешний контекст
  - Высокая скорость изменения
3. Недостоверность информации
  - Боты
  - Дезинформация

- Поиск сообществ (кластеризация графов): 1 млрд. вершин, 100 млрд. ребер
- Моделирование сложных сетей (complex networks)
- Сопоставление профилей в разных сетях ( $F_1$  - 89% при сопоставлении контактов вершины)
- Определение значений демографических атрибутов (*пол, возраст, регион проживания, семейное положение, образование; достоверность ~80%*)
- Инструменты распределенного подсчета векторных представлений вершин (graph embedding)
- Выявление ботов ( $F_1$  - 65%-82%)
- Обнаружение информационных кампаний
- **Результаты в диссертациях**
  - А.В. Коршунов (2015)
  - М.Д. Дробышевский (2019)
  - А.Г. Гомзин (2021)

# Анализ текстов

## Вызовы

1. Извлечение информации из неструктурированных текстов и полуструктурированных документов
2. Автоматическое построение баз знаний
3. Анализ эмоциональной окраски сообщений

- **Texterra:** Система анализа текстов
  - Более 20 инструментов анализа текстов
  - <http://texterra.ispras.ru>
- **DEREK:** открытый нейросетевой фреймворк для извлечения сущностей и отношений
  - <https://github.com/ispras-texterra/derek>
- **TIE:** набор инструментов извлечения информации для пополнения предметно-ориентированных баз знаний (часть платформы Talisman)
- Прикладные направления:
  - Анализ текстов социальных медиа
  - Автоматический анализ законодательства
  - Поиск заимствований
- **Результаты в диссертациях**
  - Д.Ю. Турдаков (2010)
  - Н.А. Астраханцев (2015)
  - Анонс: Ц.Г. Гукасян (2021)

# Сбор информации из открытых источников

## Вызовы

1. Обеспечение заданной **полноты** и точности в условиях ограниченных ресурсов
  2. Отсутствие фиксированных программных интерфейсов
  3. Обеспечение актуальности данных
  4. Защита от сбора данных
  5. Обработка динамических страниц
- Создана облачная инфраструктура сбора данных из **ОТКРЫТЫХ ИСТОЧНИКОВ**
    - социальных сетей (VK, Facebook, Instagram, Twitter)
    - блогов (LiveJournal)
    - сайтов СМИ
    - новостных агрегаторов (Яндекс.Новости)
    - Форумы Dark web
  - Разработано расширения для браузеров, позволяющих визуально разметит Веб-сайт для обхода и извлечения нужной информации
  - Разработаны методы автоматического построения сборщиков для некоторых категорий ресурсов (новостные сайты)

# Машинное обучение

## Вызовы

1. Минимизация усилий на получение размеченных данных для обучения моделей
  2. Проблема устаревания моделей машинного обучения (concept drift, feature drift) в работающей системе
  3. Объяснение моделей (Explainable machine learning)
  4. Безопасность использования ИИ
1. Инструменты для автоматизация получения размеченных данных
    - Активное обучение
    - Краудсорсинг
  2. Создано решение проблемы устаревания моделей
    - Проактивное обучение
    - Адаптация к новой предметной области
    - Автоматическое дообучение и контроль версий моделей
  3. Разрабатываются методы объяснения моделей
  4. Изучаются методы создания доверенного ИИ

# Решение: Talisman.Биография

The screenshot shows the Talisman Bio profile for a user named Kitayev Alexey. The interface is divided into several sections:

- ОСНОВНАЯ ИНФОРМАЦИЯ:** Includes a profile picture, URL of the account (https://vk.com/id16168168), FIO (Китаев Алексей), gender (Male), date of birth (17.08.1980, 39 years old), region (Russia, Chelyabinsk), and education.
- МАРКЕРЫ:** A section with a progress bar showing "Общий вес: 85.05%". It contains four markers:
  - 0.60: Соответствие досье на объект интереса (Document icon)
  - 2: Комментирует, "лайкает" ПОИ (Thumbs up icon)
  - 8: Наличие фотографий в военной форме, военная техника (Soldier icon)
  - 2: Пишет на профильные темы, используется терминология (Pencil icon)
- связь с досье:** Shows a link to a document titled "№ 511" for Kitayev Alexey, dated 01.11.2019 at 12:20.
- сведения из социальной сети/форума:** A list of links for profile information, messages, photo materials, account connections, and geolocation.
- сведения из системы:** A list of links for photo material comparison results and a network graph of the account.

## Область применения

- Задачи отдела кадров
- Задачи отдела по связям с общественностью
- Связывание данных сотрудников или соискателей с их аккаунтами в социальных сетях
- Верификация анкетных данных
- Обнаружение утечки корпоративной информации через аккаунты сотрудников

- Регистрация в едином реестре российских программ (№ 5547)
- Сертификация НДВ2

# Результаты

Включены в лучшие результаты РАН	<ul style="list-style-type: none"><li>• 2017 Texterra - масштабируемая платформа для извлечения семантики из текста</li><li>• 2018 Talisman - платформа анализа социальных медиа</li></ul>
Включены в Единый реестр российских программ	<ul style="list-style-type: none"><li>• Talisman.Биография</li><li>• Talisman.Поток</li><li>• Облачная среда «Асперитас»</li></ul>
Внедрение фундаментальных результатов через платформенные решения	<ul style="list-style-type: none"><li>• Внедрение решений на основе платформы Talisman</li><li>• Платформа для цифровой медицины</li></ul>



Спасибо!