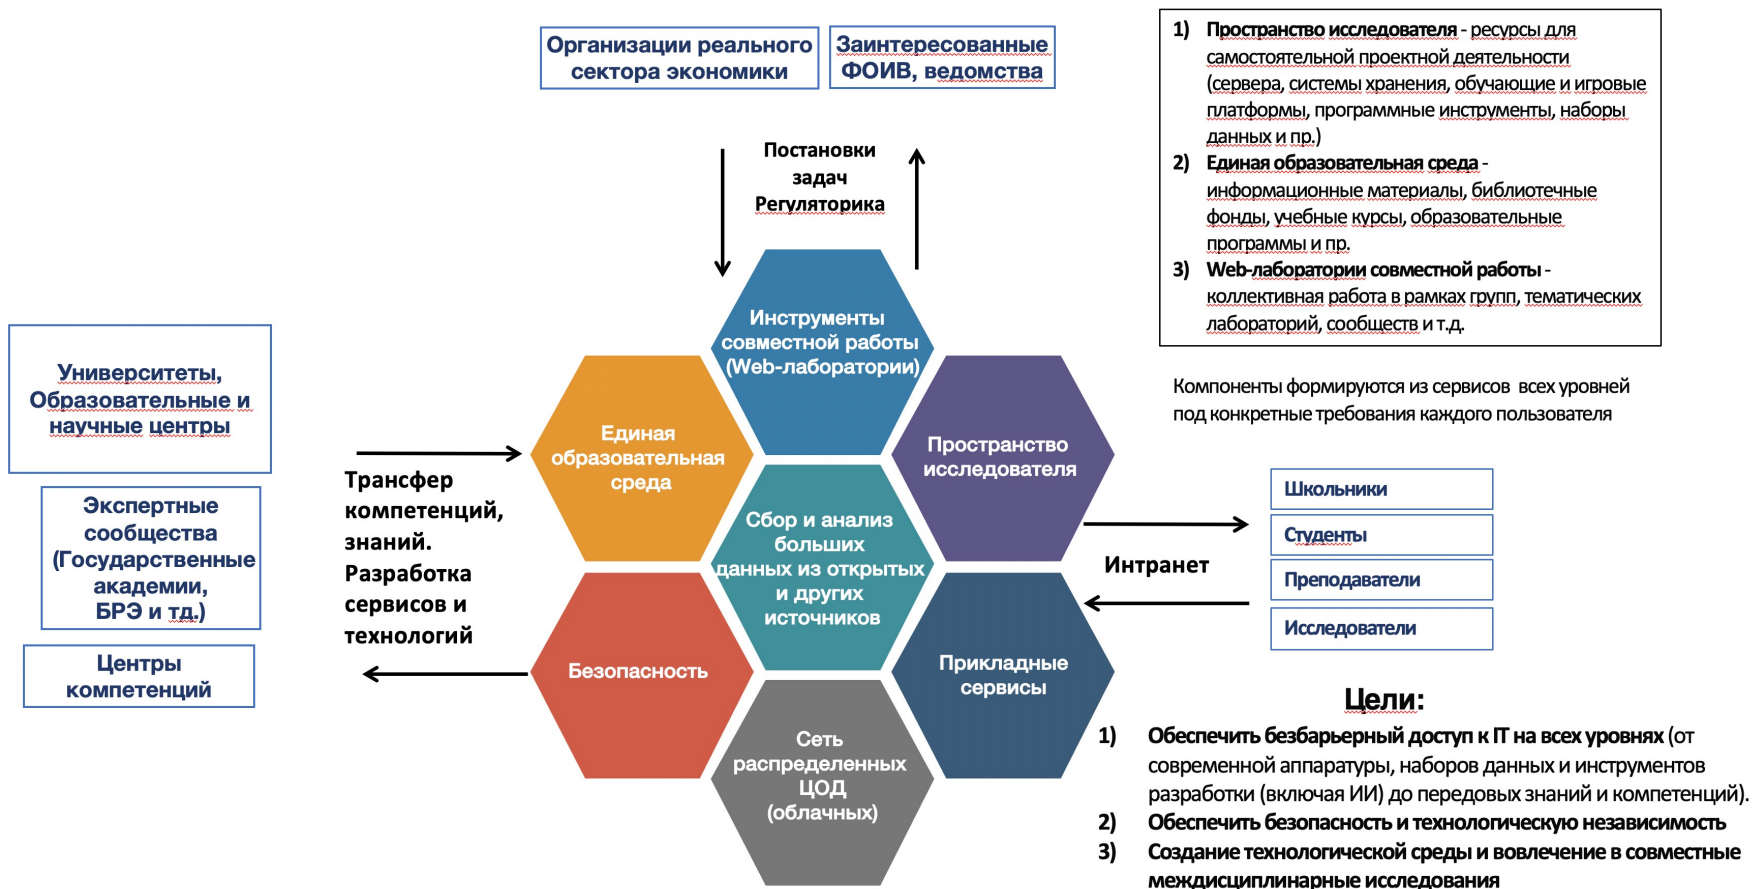


Научно-исследовательская инфраструктура крупных научных проектов - создание облачной среды, направленной на сбор и обработку больших данных

О.И. Самоваров

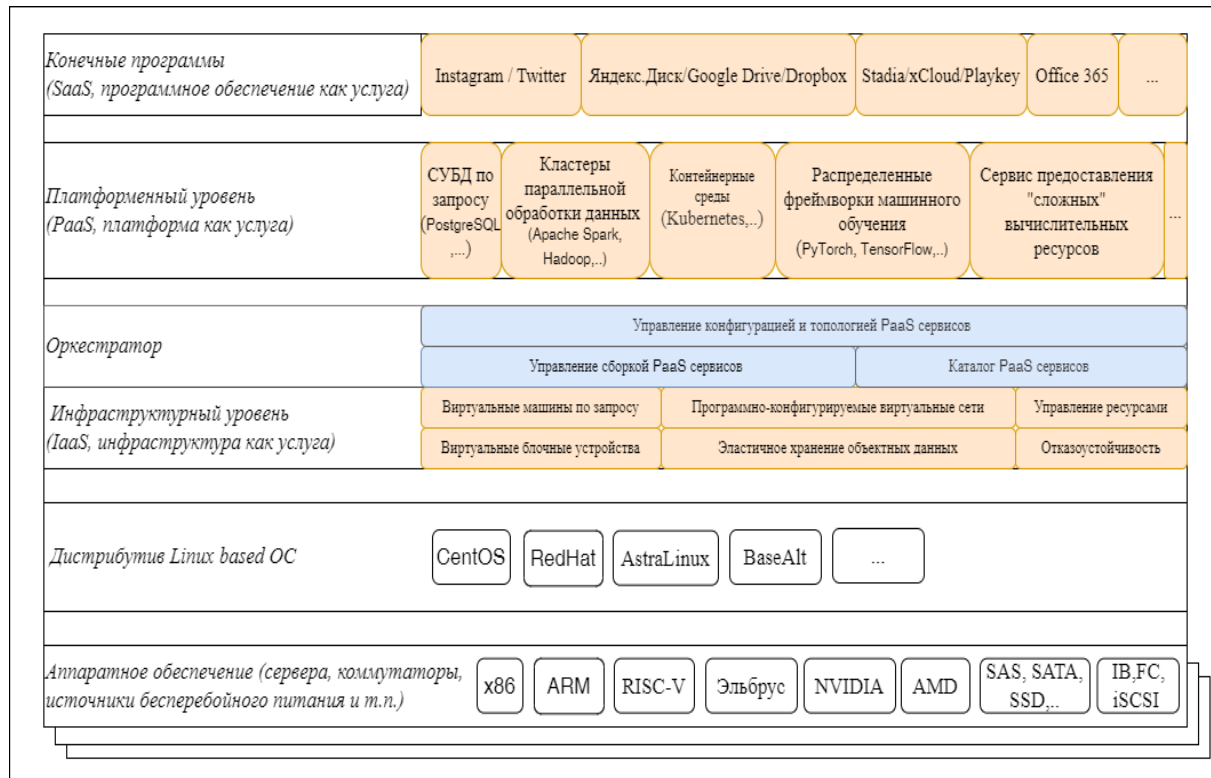
12 апреля 2024 г. Рабочее совещание по реализации программы «Соглашения о создании консорциума для IT обеспечения исследовательской инфраструктуры класса мегасайенс»

Облачная среда научных сервисов: общая концепция



«Облачный конструктор» - общая схема

Облачный “конструктор” позволяет создавать и сопровождать публичные или частные облака на всех уровнях от инфраструктуры до приложений.



Высокая динамика изменений:

- **Постоянно изменяющийся программный код** управляемых компонент и «конструктора» - сотни проектов, сотни млн. строк кода (новые дистрибутивы, постоянные обновления,...)
- **Высокая скорость изменений оборудования** (каждые 2-3 года полная замена) – новые архитектуры CPU, GPU, СХД,...
- **Требования заказчика** - новые задачи, новые платформы,...

Надо обеспечить:

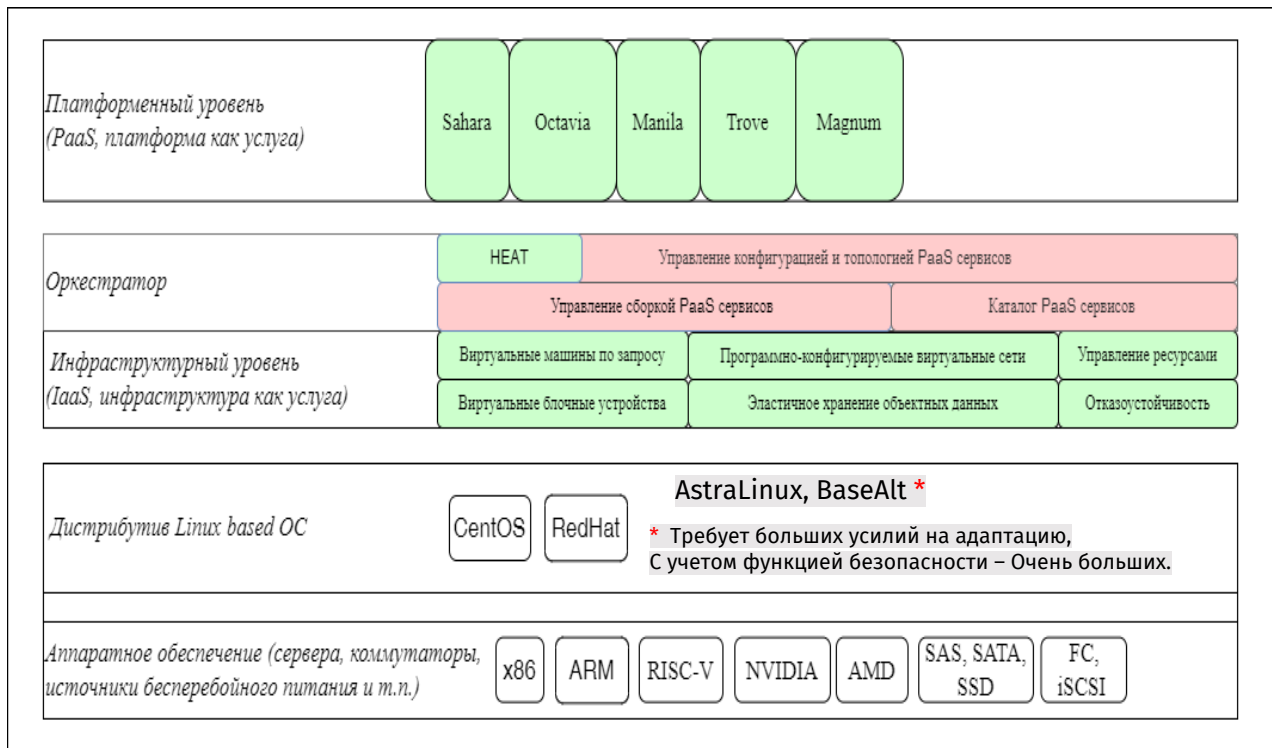
- Долгосрочное, устойчивое развитие - адаптация к изменениям и новым вызовам с минимальными ресурсами.
- Независимость от вендора базовых компонент: ОС, компонент «конструктора» и др.;
- Отчуждаемость.

Создание облачной платформы: На основе открытых решениях

Openstack (2010) *	OpenNebula (2008)	Eucalyptus (2008)
180+ провайдеров согласно каталогу Openstack, самые известные – в США Rackspace , в РФ Selectel . Из частных самый известный пример – CERN .	В основном частные облака небольшого масштаба. Самый известный пример – CERN (параллельно с Openstack) .	Только частные развертывания, проект закрыт и преобразовался в коммерческий Appscale; облачных провайдеров на этой платформе неизвестно
Полугодовой релизный цикл , последний мажорный выпуск – 22.03.2023 (с обновлением от 07.10.2023); поддержка 1-4 года в зависимости от выпуска	Нефиксированный релизный цикл , последний мажорный выпуск – 26.07.2023; поддержка 1 год	Последний мажорный выпуск – 30.04.2018, не развивается
551 контрибьютер из 81 организации только в последнем релизе (9145 контрибьютеров и 454 компании за всю историю)	40** контрибьютеров за последний релиз; 140 контрибьютеров за всю историю	42 контрибьютера за всю историю
448000 коммитов в официальных (41) проектах	20500 коммитов	26500 коммитов
Отдельные проекты поддерживаются разными командами, представленными основными компаниями-контрибьютерами (Red Hat, Rackspace, IBM, HP, Huawei, Canonical и др.)	Поддерживает команда испанцев из 8 человек **	Поддерживала команда HPE из 23 человек
Модульный, IaaS + PaaS. 5 необходимых модулей, 41 доступно всего	Монолит, только слой IaaS	Монолит, только IaaS
1.7 млн. строк кода в 5 необходимых модулях (IaaS), десятки миллионов в остальных.	0.72 млн. строк кода	0.48 млн. строк кода
В РФ: SberCloud (Сбербанк), Tionix, Accentos, Асперитас (ИСП РАН), АйТеко, VK, Рустэк (Сервионика)	В РФ: Брест (РусБИТех), Горизонт-ВС (Баррикады), Альт (Базальт), SharkXbase (Редсофт)	-

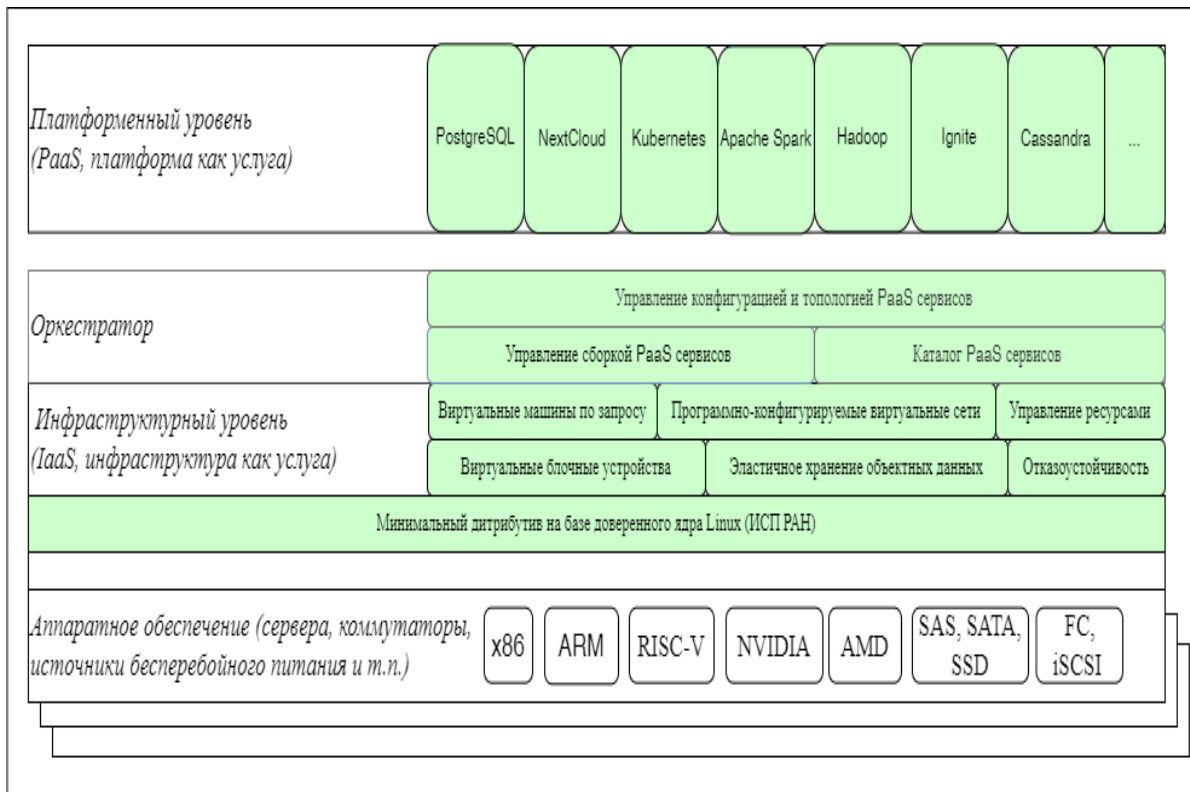
*Первый коммит ИСП РАН в OpenStack — 2012 (Fix handling of UUID-typed flavor ids, Horizon)

«Ванильный» дистрибутив OpenStack. Возможности.



- **Зависимость от внешних источников.** Сборка и обновления зависят от доступа к внешним источникам
- **Зависимость от производителя ОС.** Используется избыточный дистрибутив ОС Linux от внешнего вендора (зарубежного или отечественного)
- **Нет безопасности.** Большое количество неиспользуемых модулей. Не используется SDL
- **Нет оркестратора.** Отсутствует возможность автоматизации для разработки сервисов уровня PaaS. А Каждый сервис PaaS в OpenStack - это внешний проект. Существующими средствами разработка ведется годами до первого релиза.

OpenStack based облачная платформа ИСП РАН – Асперитас



Асперитас - это OpenStack based облачный конструктор. В дополнение к стандартным возможностям:

- Полная отчуждаемость с разворачиванием дистрибутива из своего репозитория с сохранением синхронизации из основной ветки OpenStack;
- Безопасность облака *. Используются только актуальные компоненты дистрибутива OpenStack и полный цикл SDL, от ОС до уровня PaaS без vendor-lock): Собственный UEFI с контролем целостности, минимизация зависимостей в дистрибутиве, служебные компоненты в podman, все VM в своем selinux контексте и пр.
- Michman - Оркестратор ИСП РАН обеспечивает автоматизированное создание PaaS сервисов (стандарт OASIS TOSCA);
- «Fanlight» - виртуальные рабочие столы (DaaS). Сервис уровня PaaS для создания VDI решений, игрового стриминга и пр.

* В том числе, по требованиям ФСТЭК России

Мичман vs другие оркестраторы (I)

Управление PaaS сервисами требует специальной сущности для их предоставления и сопровождения: **оркестратор платформенных сервисов**.

Среди провайдеров облачных услуг встречаются следующие ситуации.

1. Отсутствие оркестратора (большинство провайдеров):

- PaaS-сервисы добавляются либо вручную,
- либо с использованием Kubernetes, но всё равно само добавление и адаптация происходят полностью в ручном режиме.
- Добавляемый сервис изначально должен уметь использовать Kubernetes для управления своим жизненным циклом

2. Отдельные проекты Openstack

- Openstack сам по себе содержит в себе ряд платформенных сервисов:
 - Sahara - большие данные (мы туда коммитили)
 - Manila - сетевые файловые системы по запросу
 - Octavia - балансировщик нагрузки
 - Trove - базы данных как сервис
 - Magnum - управление контейнерами
- **Однако:**
 - Создание нового такого сервиса — полноценный большой проект; каждый из этих проектов развивался 4+ лет чтобы войти в состав Openstack. Каждый сделан по-своему.
 - Работают они *не очень хорошо*; некоторые зависят от внешних источников пакетов.
 - Список очень ограничен.
 - Обновить даже версии предоставляемых сервисов можно только с новым релизом Openstack.

3. Наш собственный оркестратор: **MICHMAN**



- Для описания PaaS-сервисов мы используем специальный язык описания, соответствующий стандарту OASIS TOSCA (Topology and Orchestration Specification for Cloud Applications)
- Этот язык позволяет описать любой PaaS сервис, его жизненный цикл и зависимости. Мы описываем сервисы на этом языке и получаем готовый к запуску PaaS-сервис. Спецификация языка описания открытая
- Сервис, описанный на таком языке, можно развернуть как на голом железе, так и на виртуальных машинах, так и в контейнерных средах — с точки зрения языка описания это неважно. Более того, такой сервис может располагаться в нескольких облаках, или на голом железе + в облаке
- Единственный работающий аналог — коммерческий, американский и получить его можно только по запросу (ubicity.com)
- **Это позволяет нам добавлять PaaS-сервисы “конвейерным” образом**
- **Подготовить PaaS сервис можно используя примеры и спецификацию**

- ✓ Конвейер полного жизненного цикла разработки моделей ИИ и наборов данных биомедицинского домена (mlops платформа)
- ✓ Развертывание VDI решений и виртуальных Web-лабораторий

Базовые задачи платформы для анализа биомедицинских данных

- ✓ Надежное хранение больших биомедицинских данных.
- ✓ Организация процесса получения и аннотирования наборов данных.
- ✓ Долгосрочное развитие и поддержка жизненного цикла моделей машинного обучения.
- ✓ Совместная работа распределенных междисциплинарных команд.
- ✓ Обеспечение необходимого уровня доверия к ИИ.



Получение данных из различных источников

Хранение больших биомедицинских данных

Преобразование данных

Аннотирование биомедицинских данных

Обучение моделей

Тестирование и развёртывание моделей

Публикация моделей и сервисов на основе моделей

Функции

Интеграция с внешними системами (МИС, ЛИС и т.п.)

Интеграция с носимыми устройствами

Сбор данных из открытых источников

Отказоустойчивость

Масштабирование

Версионирование

Сертификация

Реестр моделей

Реестр наборов данных

Конвертация форматов данных

Домен-специфичная предобработка (приведение частоты дискретизации ЭКГ, предобработка данных МРТ и т.д.)

Выбор подмножества данных (пол, возраст, фильтрация шумных данных)

Домен-специфичные инструменты аннотирования биомедицинских данных

Формирование правил аннотирования

Автоматизация аннотирования, распределение задач и тестирование экспертов

Создание верифицированных наборов данных

Интеграция вычисления согласия экспертов в процесс аннотирования

Управление данными и конфигурацией эксперимента

Эксплоративный анализ и подготовка данных (построение признакового пространства, аугментации и т.д.)

Версионирование моделей

Low-code средства разработки моделей и AutoML

Визуализация метрик обучения

Анализ результатов обучения моделей

Уточнение требований к задачам на аннотирование

Валидация моделей на доступных наборах данных, полученных с других медицинских устройств, от различных организаций и регионов

Развёртывание и балансировка нагрузки

Витрина скрининговых сервисов и СППВР

Получение обратных связей от пользователей моделей и сервисов

Виртуальные рабочие столы для десктопных сервисов

Базовая сервис-ориентированная платформа

API для загрузки данных

API для работы с системами хранения

Управление пайплайнами предобработки данных

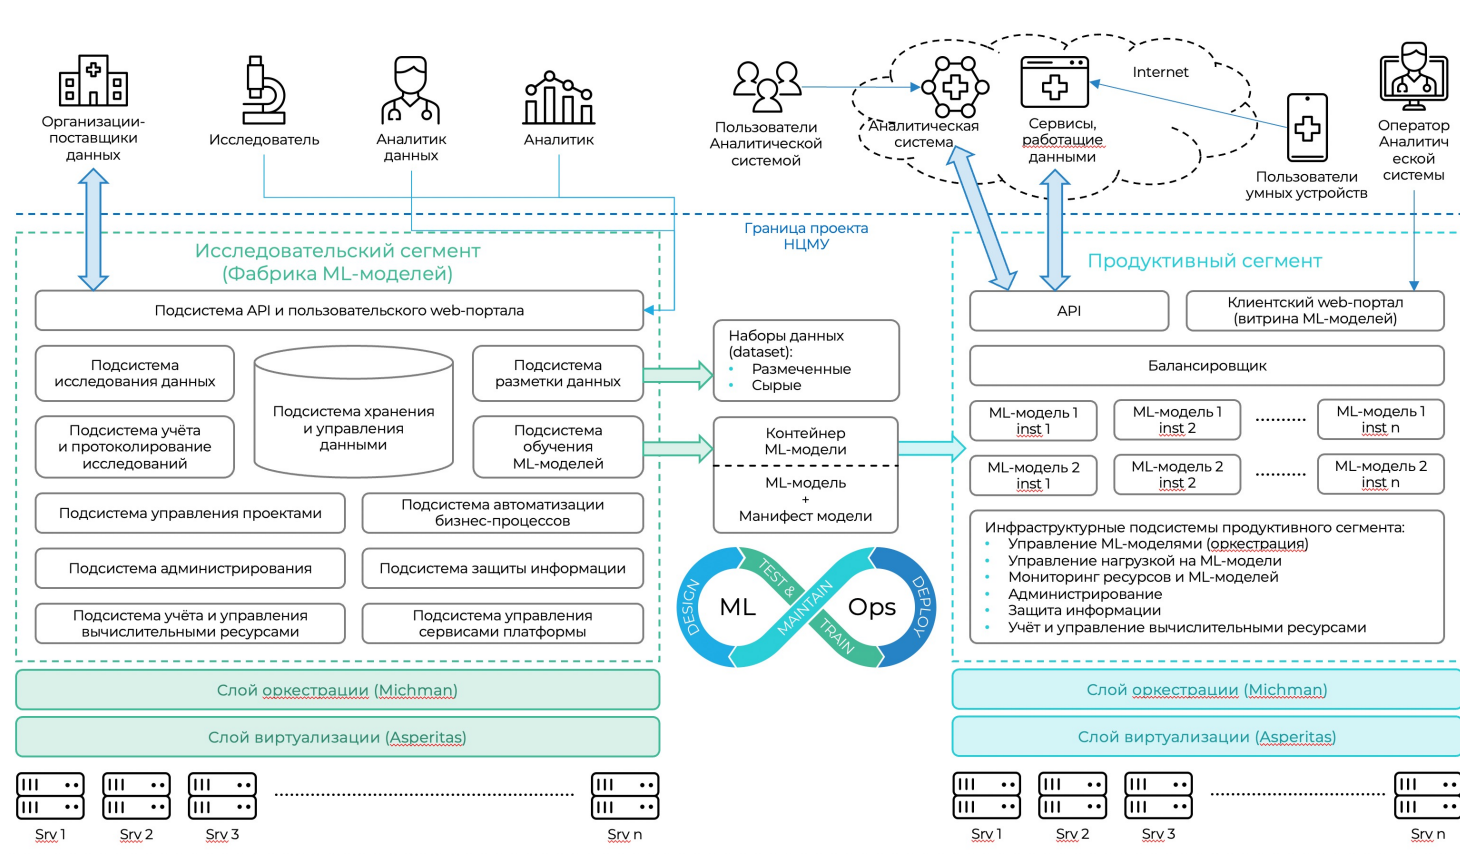
API для интеграции инструментов аннотирования и вычисления согласия экспертов

Инфраструктура и сервисы машинного обучения на графических ускорителях (видеокартах), сервисы доверенного ИИ

Сервисы MLOps

Сервисы мониторинга

Платформа для интеллектуального анализа биомедицинских данных – Архитектура




- Конвейер полного жизненного цикла разработки моделей ИИ и наборов данных:
- подготовка наборов данных (механизмы краудсорсинга при разметке данных; контроля качества разметки; автоматизации подготовки наборов данных);
 - разработка, обучения нейросетевых моделей с использованием доверенных фреймворков и их управления
 - SDL.

Платформа для интеллектуального анализа биомедицинских данных – стек технологий

Базовая платформа ИСП РАН

Прикладные решения



ИСП РАН SCINOON Прикладные инструменты jupyter CVAT

ИСП РАН TALISMAN ТЕХТЕРРА DEDOC Технологии анализа данных
 Сбор открытых данных
 Анализ медиа
 Анализ текстов
 Анализ изображений
 Анализ временных рядов
 Машинное обучение

ИСП РАН ASPERITAS MICHMAN FANLIGHT Облачная инфраструктура, системы оркестрации
 Система хранения больших данных

ИСП РАН Баикал ЭЛЕКТРОНИКС МЦСТ ЭЛЬБРУС Аппаратное обеспечение RISC-V x86



Медицинские информационные системы



Открытые данные



Государственные порталы



Платформа для интеллектуального анализа биомедицинских данных – примеры решения задач

Добро пожаловать, Дмитрий!

Продолжите свои исследования или назначьте новые

Мои исследования + Создать

Исследования 10 Датасеты 3 Модели 1 Сервисы 0

Исследования в тренде

Исследование 001 Длинное название на пару строк, а что не влезло – под знаком с и...

Исследование 001 Длинное название на пару строк, а что не влезло – под знаком с и...

Исследование 001 Длинное название на пару строк, а что не влезло – под знаком с и...

Исследование 001 Длинное название на пару строк, а что не влезло – под знаком с и...

Датасеты в тренде

Датасет 001 Длинное название на пару строк, а что не влезло...

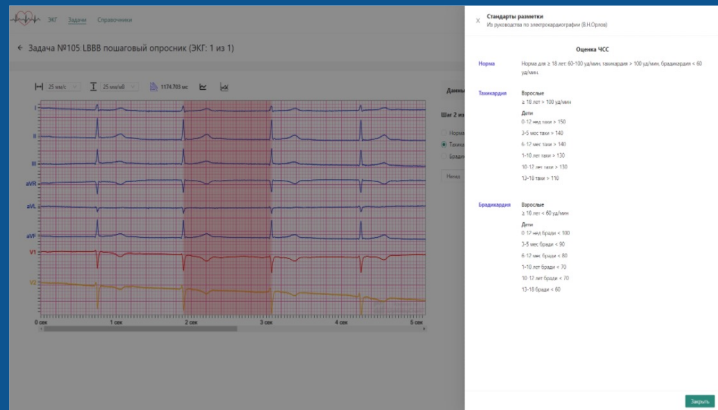
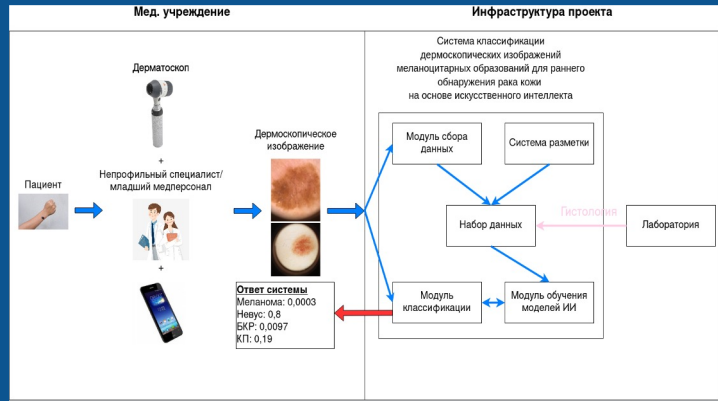
Датасет 001 Длинное название на пару строк, а что не влезло...

Датасет 001 Длинное название на пару строк, а что не влезло...

Датасет 001 Длинное название на пару строк, а что не влезло...

Датасет 001 Длинное название на пару строк, а что не влезло...

Датасет 001 Длинное название на пару строк, а что не влезло...



Облачная среда научных сервисов: технологический стек

Организации
реального сектора
экономики

Экспертные сообщества,
Государственные
академии

Заинтересованные **ФОИВ,**
ведомства

Университеты,
образовательные и
научные центры

**Международные
участники**

Пространство исследователя :: Образовательная среда :: Web-лаборатории

Прикладные сервисы

TALISMAN.Биография



VisOntia



TALISMAN.Поток



SciNoon



- Анализ социальных сетей
- Образовательные платформы
- Интеллектуальный поиск
- Обработка текстов
- Представление знаний
- Обработка текстов

Инструменты сбора, хранения
и анализа больших данных

TALISMAN



TensorFlow



Yandex CatBoost



ignite



spark



ROB



Files



Social



News



Devices



Sensors



IoT



Платформа
управления
ПЖЦ моделей
ИИ и наборов
данных

- Инструмент работы с большими данными
- Интеграция с внешними и внутренними «поставщиками» данных
- Технологии AI, ML, DL
- AI Ready данные

Облачная среда

ASPERITAS



openstack.



MICHMAN



kubernetes



FANLIGHT



- Миграция legacy-систем в облако
- Инфраструктура как сервис на базе Openstack (IaaS)
- Платформенные сервисы по запросу (PaaS)
- Микросервисная архитектура и контейнеризация

Аппаратные платформы



Сеть распределенных ЦОД

Предоставит простой
доступ в модели сервисов:

- **Готовая инфраструктура** с возможностью гибкой настройки (сервера, хранилища, GPU, сети и пр.).
- **Готовые платформы** с возможностью создавать новые (распределенные БД, кластеры обработки, платформы разработки и т.д.);
- **Приложения по запросу** (тематические Web-лаборатории, стенды отработки решений, Аналитические системы,)

Позволит:

- **Создать цифровую колобаритивную среду** междисциплинарных команд для решения конкретных задач науки и образования с вовлечением индустрии;
- **Повысить эффективность**, исключив дублирование, сконцентрировав ресурсы (человеческие и материальные);
- **Прогноз развития на основе внутренней аналитики** создаваемых и собираемых данных с использованием методов ИИ

Спасибо за внимание