

Машина
Искусственного Интеллекта
Скала[^]р



Скала[^]р – модульная платформа

для построения инфраструктуры высоконагруженных
корпоративных и государственных информационных систем



10 лет
серийного
выпуска

680

комплексов
в промышленной
эксплуатации

10 тыс. +
вычислительных
узлов

Продуктовые направления Скала[^]р

решения для высоконагруженных корпоративных и государственных систем



Динамическая инфраструктура

Машины динамической инфраструктуры Скала[^]р МДИ
на основе решений BASIS для создания динамической конвергентной и гиперконвергентной инфраструктуры ЦОД и виртуальных рабочих мест пользователей



Инфраструктура ИИ

Машина искусственного интеллекта Скала[^]р
на основе оптимизированного программно-аппаратного стека для максимальной производительности при работе с моделями ИИ



Управление данными

Машины баз данных Скала[^]р МБД

на основе решений Postgres Pro для замены Oracle Exadata в высоконагруженных системах с обеспечением высокой доступности и сохранности критически важных данных

Машины больших данных Скала[^]р МБД

на основе решений ARENADATA и PICODATA для создания инфраструктуры хранения, преобразования, аналитической, статистической обработки данных, а также распределенных вычислений

Машины хранения данных Скала[^]р МХД

- на основе технологии объектного хранения S3 для геораспределенных катастрофоустойчивых систем с сотнями миллионов объектов различного типа и обеспечения быстрого доступа к ним
- решения на основе платформы S3 и российского ПО для комплексных задач резервного копирования и восстановления крупных массивов данных со встроенной иерархией хранения и обеспечением высокой доступности копий



Специализированные решения

Машина управления технологическими процессами Скала[^]р МСП.ТП (АСУ ТП)

Высоконадежная инфраструктура для различных АСУ ТП промышленных предприятий с высокими требованиями к отказоустойчивости и информационной безопасности. Соответствует требованиям ЗОКИИ, в том числе критериям к Доверенным ПАК

Машина автоматизированных банковских систем Скала[^]р МСП.БС

на платформе Машин Скала[^]р для задач класса АБС и процессинговых решений с поддержкой высокой транзакционной и аналитической нагрузки, сегментирования баз данных и обеспечения ИБ

Модульная платформа Скала[®]



Использование опыта технологических лидеров – гиперскейлеров

Единый принцип модульной компоновки и платформенный подход

Единая облачная система управления сервисами



IaaS



PaaS



DBaaS

Программная платформа Скала[®] для управления ресурсами и эксплуатацией



Разделение ресурсов



Мультитенантность



Автоматизация

Динамическая инфраструктура

Серверная виртуализация
Dynamix Standard

Гиперконвергентия
Dynamix Standard

Контейнеризация приложений
Deckhouse

Частное облако
Dynamix Enterprise

Виртуализация рабочих мест
WorkPlace

Моноглавная СУБД
Postgres Pro

Шардированная СУБД
Postgres Pro

Реидентская обработка
Tarantool

Гибридная СУБД
YandexDB

Массивно-обработка
Greenplum

Аналитическая обработка
ClickHouse

Неструктурированные данные
Hadoop

Потоковая обработка
Kafka и NiFi

Объектное хранение
S3

Резервное копирование

Искусственный интеллект

Автоматизированные банковские системы

АСУТП

Модульная платформа

Инфраструктура управления данными

Транзакционная обработка

Большие данные

Интеллектуальное хранение

ИИ

Специализированные решения

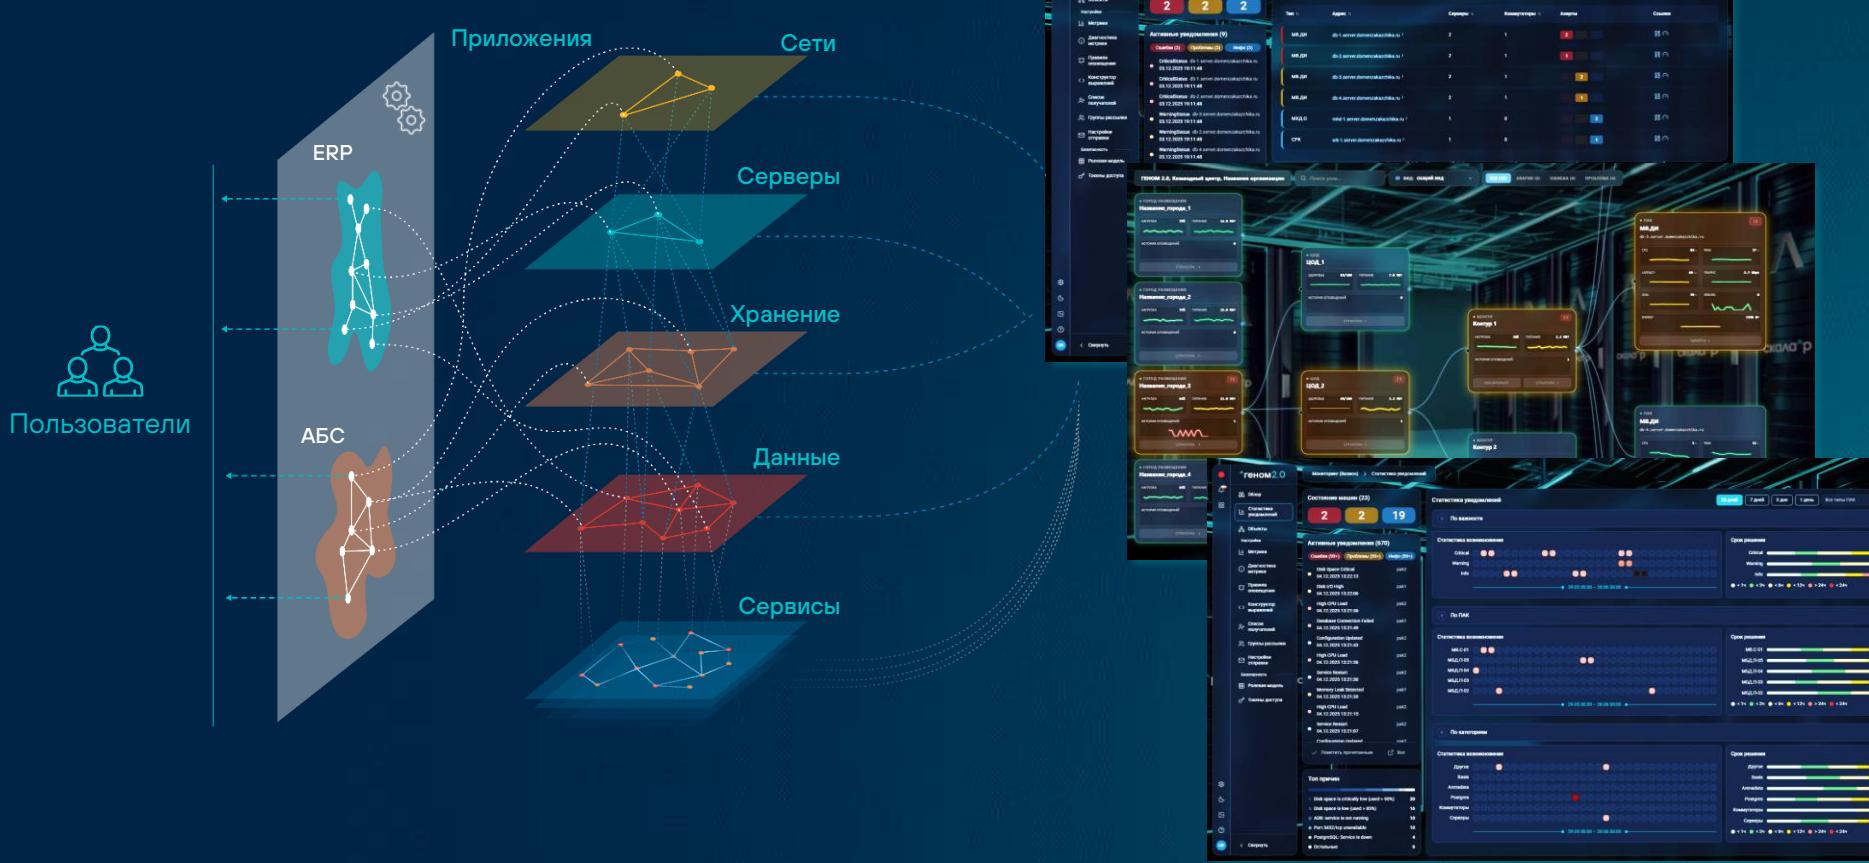
Динамическая инфраструктура

Глубокая интеграция и встречаная оптимизация компонентов по всему технологическому стеку под определенные нагрузки

Развитие: Программная платформа Скала^р



объединение различных доменов управления в единую объектно-сервисную графовую модель - комплексное решение для эксплуатации инфраструктуры уровня ЦОД



- Единая точка обзора состояния контура
- Обозримость и удобство управления ЦОД
- Цифровой двойник инфраструктуры
- Контроль изменений оборудования и сервисов
- Моделирование изменений в инфраструктуре
- Высокая степень автоматизации

ПАК Скала[®] в Реестрах РФ



Машины (ПАК)

Модули (ПАК)

Компоненты

ГИСП
государственная
информационная система
промышленности

МИНПРОМТОРГ
РОССИИ

Все сервисы ГИСП

Реестр промышленной продукции, произведенной на территории
Российской Федерации

Машины (ПАК)

Модули (ПАК)

Программное обеспечение



РЕЕСТР
ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ

Российский

Евразийский

ПАК Скала[®]

Соответствуют критериям доверенного ПАК (ПП 1912)

- Технологическая независимость
- Информационная безопасность
- Функциональная устойчивость

Импортозамещение: сложность выбора

Отсутствие технологического лидерства



Глобальный ИТ-рынок



Российский ИТ-рынок



Проблемы отсутствия ИТ-лидеров на российском рынке

- Отсутствие информации и практического подтверждения совместимости продуктов
- Время и ресурсы для подтверждения соответствия заявленной функциональности
- Проблема совместимости с продуктами из разных классов
- Размытие понятия «лидер»: в каждом сегменте существуют десятки на первый взгляд равнозначных продуктов

Импортозамещение: варианты перехода



Покомпонентное замещение:

- Время на изучение вариантов, тестирование и выбор
- Лавина взаимосвязанных проектов по внедрению
- Сложность синхронизации дорожных карт развития
- Рост сроков внедрения и рисков на стыках



Создание целевой доверенной ИТ-инфраструктуры:

- Последовательный перевод систем на целевую доверенную ИТ-инфраструктуру
- Снижение нагрузки с текущей инфраструктуры и отсутствие необходимости ее масштабирования
- Сокращение сроков внедрения и снижение рисков



Почему ПАК Скала^р?



Высокая отказоустойчивость

За счет специализированной модульной и кластерной архитектуры решений

Экономия до 90%
на проектировании и внедрении

Продукты развиваются
с учетом пожеланий Заказчиков

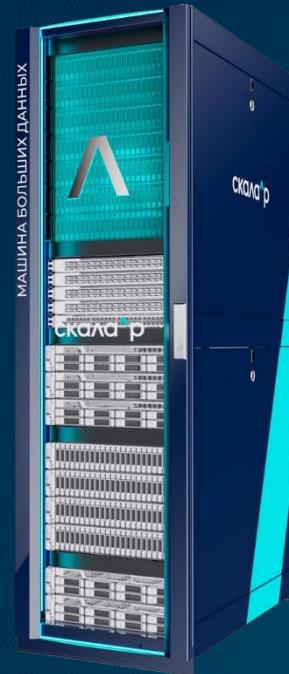
Высокая доступность
и катастрофоустойчивость из коробки

Соответствие требованиям ИБ

Российское оборудование и ПО

Высокая производительность

Встречная оптимизация и устранение узких мест
по всему стеку применимых технологий



Единая техническая поддержка

Сопровождение оборудования и программного
обеспечения всех компонентов Машин

Ускорение до 30%
проектов **импортозамещения**

Кратное **сокращение инцидентов**,
связанных с ошибками эксплуатации

Удобство закупочных процедур для ПАК и Модулей –
это **номенклатурные позиции Реестра РЭП**
Минпромторга РФ

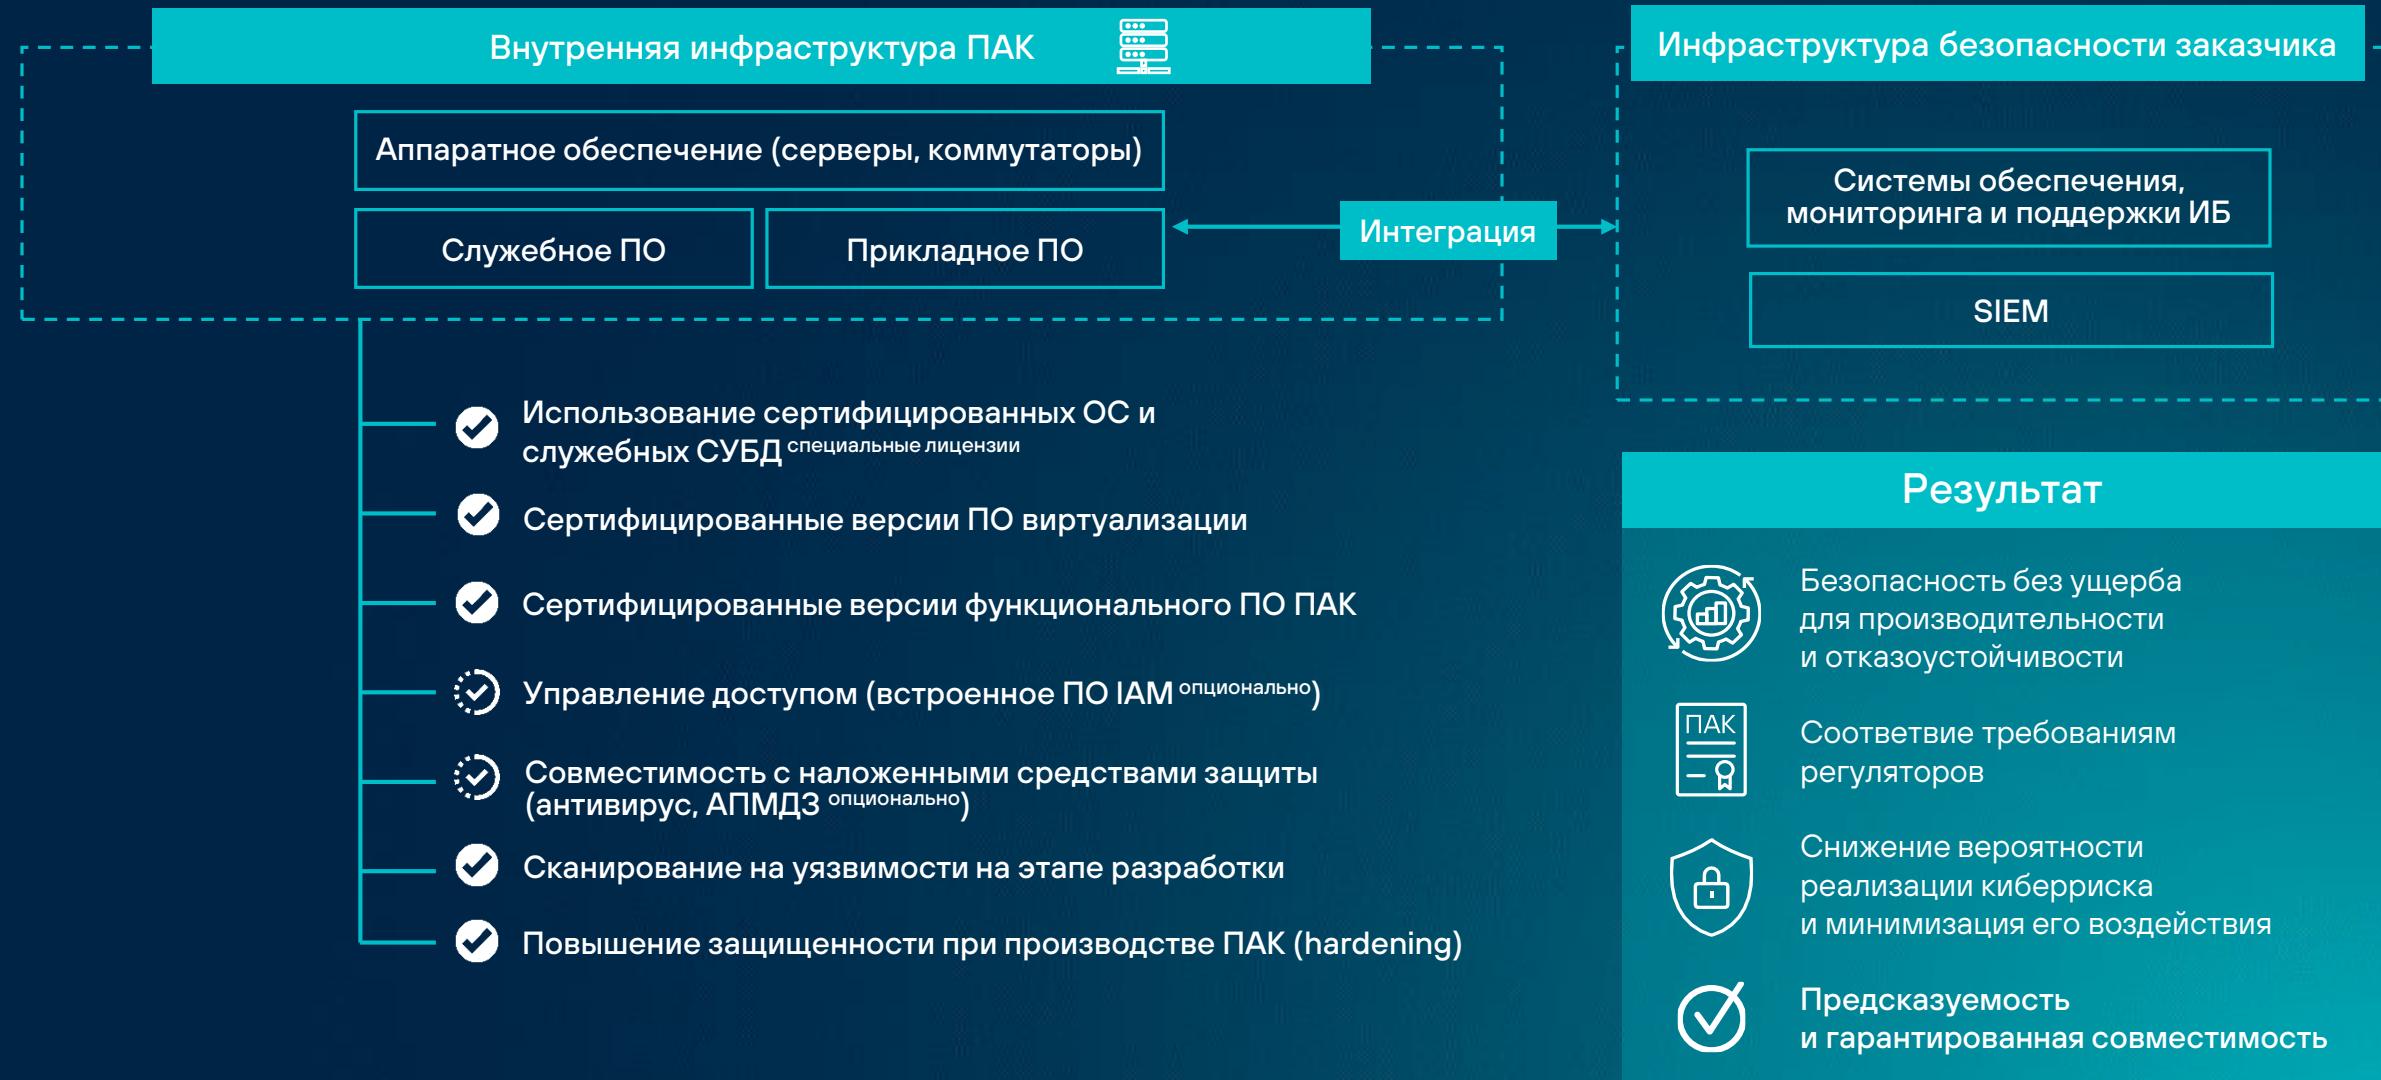
Соответствие актуальному законодательству
по закупкам – **преференции изделиям**

Применение для КИС и ГИС,
включая **доверенные ПАК** для КИИ

Прямое взаимодействие с технологическими партнерами по развитию необходимого Заказчикам функционала

ПАК – Программно-аппаратные комплексы и Модули платформы – включены
в Реестр российской промышленной и радиоэлектронной продукции, **ПО Скала^р** – в реестр Минцифры

Все ПАК Скала[®]р: встроенная безопасность





Машина искусственного интеллекта Скала[^]р



Метрики по ПАК ИИ



Производительность

$\geq 6 \text{ Pflops}$

на один рабочий узел (TF32)

$\geq 400 \text{ Tflops}$

на один рабочий узел (FP32)

Масштабирование сети с применением RDMA увеличивает производительность и уменьшает задержки более чем в 2 раза, что критично для моделей ИИ, работающих на распределённом кластере со сложной топологией

Максимальный размер LLM

до 235B параметров

в один рабочий узел без квантования

Использование NVLink для LLM
увеличивает TPS

примерно

в 2-5 раз

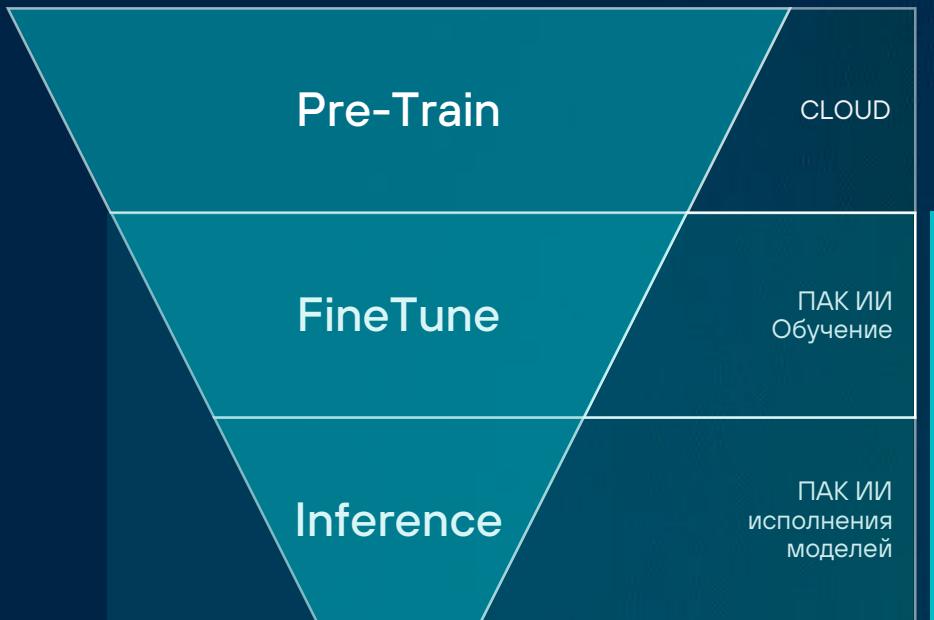
в зависимости от количества
пользователей и типа запросов

Машина искусственного интеллекта Скала^р



Задачи

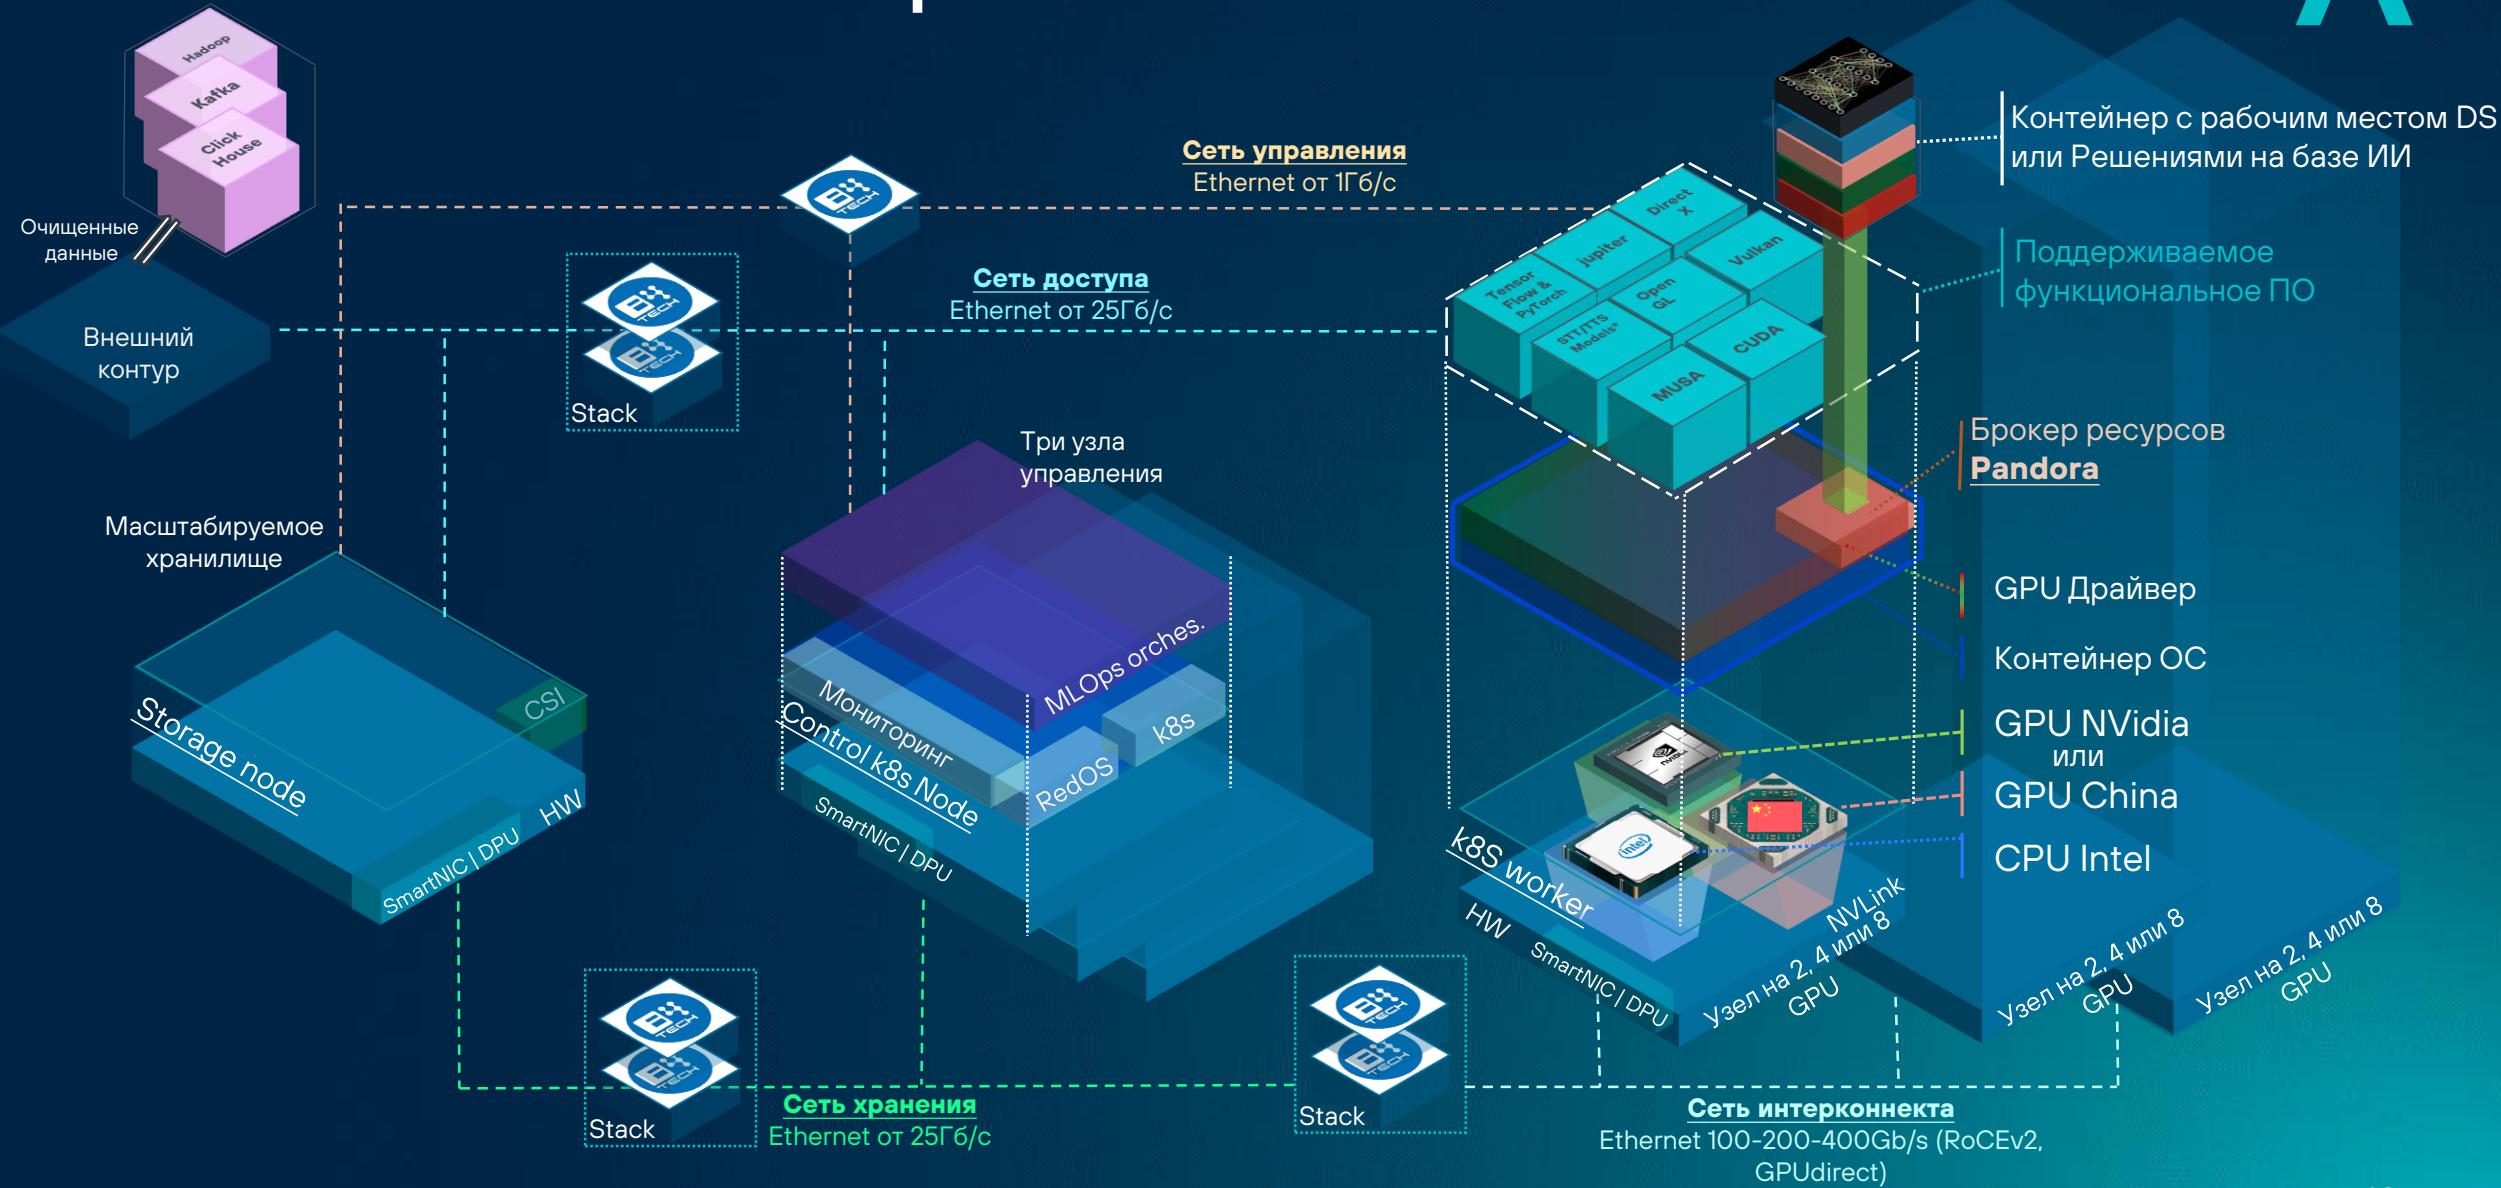
ПАК предназначен для обеспечения on-premise инфраструктуры для обучения и исполнения ИИ



Аналог:
Huawei Atlas 900 Pod
NVIDIA DGX SuperPOD



Машина ИИ Скала[®]р -HLD



Преимущества Машины ИИ Скала[▲]р



Платформенные решения позволяют сократить

- в 15 раз время подготовки среды разработки
- в 5 раз время работы data-инженеров и data-аналитиков*



Реализация каталога ИИ решений от валидированных партнеров на базе ПАК ИИ



Надежная мультивендорная Enterprise-инфраструктура с оптимальной конфигурацией и стабильным программно-аппаратным стеком на основе проведенных тестов и лучших практик.



Соответствие требованиям соблюдения принципов отказоустойчивости, масштабируемости на уровне архитектуры для использования в критичных и высоконагруженных корпоративных и государственных информационных системах



Исключение инцидентов на стыке технологий и высококвалифицированная поддержка Скала[▲]р



Расширение возможностей как вертикального, так и горизонтального масштабирования



Предсказуемые характеристики, метрики функционирования платформенных решений



Управление жизненным циклом корпоративных ИИ решений



Поддержка регуляторных требований, отраслевых стандартов



Увеличение производительности*

- в 3 раза при обучении ML моделей
- в 4 раза обученных ИИ моделей



Безопасное использование популярных языковых моделей LLM в закрытом контуре

* Показатели могут варьироваться в зависимости от задачи

Выгоды ПАК ИИ



Стандартизация и ускорение разработки

ПАК ИИ состоит из готового набора проверенных моделей и инструментов управления «Pandora», стандартизирует рабочие процессы, гарантирует совместимость всех аппаратных и программных компонент, сокращает сроки внедрения ИИ до 80%.



Развитие компетенций команды

ПАК ИИ автоматизирует жизненный цикл внедрения и работы с ИИ, что способствует росту квалификации IT-специалистов внутри компаний и снижает зависимость от внешнего рынка труда.

Развитие «IT-специалисты -> MLDevOps -> ML инженеры -> DataScience»



Эффективная и гибкая масштабируемость

Использование НРС-технологий и отработанный план модернизации обеспечивают экономичную масштабируемость, гибкость выбора технологий и оптимизацию ресурсов.



Безопасность и изоляция данных

Подход «безопасность интегрированная в архитектуру» (secure by design), каталог доверенных компонентов и возможность работы в изолированном-контуре обеспечивают защиту от утечек и компрометации разрабатываемых решений с ИИ.



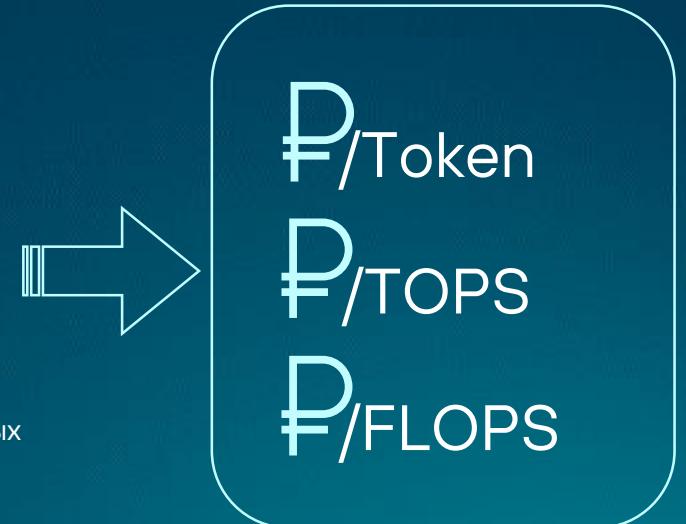
Гарантированная производительность, поддержка и простота развёртывания

Решение обеспечивает гарантированную производительность и техническую поддержку благодаря уже собранным и протестированным компонентам, оптимизированным под реестровое оборудование и программное обеспечение. Это особенно важно для инфраструктур на базе российского стека, где зачастую отсутствуют специалисты, способные с нуля оперативно собрать и настроить весь ИИ-контур.



Опыт рынка

Собраны лучшие практики и потребности со всего рынка, что уменьшает вероятность неполноты инструментов и решения проекта к проекту



Как итог улучшения показателя
рубль за единицу вычисления



Импортозамещение

Соответствие требованиям регуляторов и уменьшение санкционных рисков;

Примеры использования ИИ для корпоративных задач*



1 Совершенствование процессов технической поддержки продуктов компании

IT.ONE

Автономная [система для классификации, маршрутизации](#) поступающих [обращений клиентов](#) по разным каналам связи на корректную линию технической поддержки.

Построена на основе обработки естественного языка с применением адаптированных языковых моделей LLM.

2 Повышение эффективности клиентского сервиса

Чат-бот [технической поддержки клиентов](#) для информирования, ответов на общие вопросы, уточнения дополнительной информации.

Построен на основе технологии обработки естественного языка и дообученных языковых моделях LLM.

3 Совершенствование внутренних процессов по повседневной работе сотрудников

Расшифровка [аудиозаписей](#) встреч с суммаризацией итогов, определения решений и поручений по аудиозаписи: на основе обработки естественного языка, транскрибация, применение адаптированных языковых моделей LLM.

5 Повышение эффективности разработки и тестирования программных продуктов компании

Чат-бот [для разработчиков и тестировщиков](#), с поддержкой [используемых языков программирования с учетом кодовой базы клиентских продуктов](#) (ПО) во внутреннем контуре компании.

Создание изолированной ИТ-инфраструктуры для эксплуатации результатов инициатив ИИ.

4 Создание единого связанного пространства данных из разнородной информации документов ограниченного доступа, приходящих в ответ на запросы контролирующих органов государственной власти федерального уровня

Автономное (on-premise) ИИ-решение на основе LLM, в формате ПАК для автоматического извлечения данных из неструктурированных документов и автоматического формирования фабулы документа с гибкой настройкой правил извлечения данных.

6 Повышение эффективности процессов управления проектами компании

Интеллектуальный помощник (чат-бот), повышающий [эффективность повседневной работы](#) руководителей проектов с внутренней документацией, базой знаний и регламентами компании, хранящимися в разнородных внутренних корпоративных сервисах компании.

Построен на основе адаптированных языковых моделей LLM, интеллектуального алгоритма для контекстного поиска, агрегации данных и предоставления структурированных ответов через интуитивный интерфейс чата.

7 Формирование у сотрудников компетенций, позволяющих использовать доверенные технологии ИИ

Средства обучения сотрудников промпт-инжинирингу и мотивации использования ИИ на основе.

Построены на больших фундаментальных языковых моделях (облачных) для выполнения текущих задач.

8 Совершенствование процессов подбора сотрудников

Система скрининга соискателей на соответствие требованиям позиции (вакансии).

Построена на основе технологий NLP и применения адаптированных языковых моделей LLM.

* Типовые задачи для инфраструктуры Машины ИИ Скала[®]

Риски и сложности внедрения ИИ



Внедрение ИИ кардинально отличается от внедрения готовых программных продуктов (ERP, CRM, ITSM и т.п.) и от разработки ПО на заказ

- В процессе реализации ИИ-проекта доступен широкий спектр продуктов на рынке ИИ
- Список ИИ продуктов еженедельно меняется и появляются новые как решения так и технологии
- В процессе реализации ИИ-проекта подбираются и апробируются разные ИИ продукты

Для реализации ИИ инициатив нужны разные ИИ-специалисты (DataScience, ML-инженер, DevOps, Аналитик и т.п.)

- Специалистов очень мало на рынке и стоимость высокая
- Высокая конкуренция за ИИ-специалистов
- Долгий срок подготовки и возвращения специалистов даже при наличии наставников
- Зависимость ИИ-проектов от носителя знания или компетенции

ИИ инфраструктура дорогая

- Основная стоимость это графические ускорители и интерконнект
- Требуются специализированные аппаратные решения
- Потенциальные сложности и ограничения при масштабировании ИИ инфраструктуры

Комплексность ИИ решений усложняет организацию ИБ

- Во время интеграции в контур компании есть высокий риск получить дыру в безопасности
- Во время эксплуатации возникают дополнительные риски утечки данных

- ПАК стандартизирует аппаратно-программные решения, гарантируя их совместимость, универсальность, сохранение уровня доверия к ИИ и возможность модернизации

- Готовый набор проверенных моделей и ИИ продуктов, входящих в состав Pandora
- Сокращение срока разработки и внедрения ИИ до 80%

- ПО автоматизации управления ЖЦ Машины ИИ (Pandora) позволяет развивать ИТ-специалистов, что снижает зависимость от рынка труда в сфере ИИ
- IT-специалисты -> MLDevOps -> ML инженеры -> DataScience

- Экономия на дальнейшей масштабируемости за счёт применения HPC технологий и устранении узких мест
- Отработанный план модернизации продукта от тестовой среды до ИИ-фабрики
- Обеспечена вариативность между NVIDIA, азиатскими вендорами и другими
- Оптимизация требуемых ресурсов от задачи к задачи

- Обеспечение безопасности ИИ сервисов за счёт подхода TRISM/secure by design и каталога доверенных контейнеров, готовых к запуску на on-premise инфраструктуре, в закрытом контуре
- ПАК может функционировать в изолированном контуре, предотвращая утечки данных
- Использование доверенных ИИ компонентов из его каталога и листа совместимости, минимизирует риски компрометации конечного продукта



₽/Token
₽/TOPS
₽/FLOPS

Как итог улучшения
показателя рубль за единицу
вычисления

Импортозамещение: Соответствие требованиям регуляторов и уменьшение санкционных рисков

Размеры Машины Скала^р МИИ



Тестирование / Демо		Разработка / MVP		Продакшн (корпоративный)		AI Factory (полный цикл)	
Сеть	Сеть опционально	Сеть	Сеть доступа	Сеть	Сеть доступа/хранения	Сеть	Сеть доступа
Вычисления	Сервер на 4-8 GPU + NVLink и/или Сервер на 2 GPU	Вычисления	Сервер на 4-8 GPU + NVLink и/или Сервер на 2 GPU	Вычисления	2 сервера на 4-8 GPU + NVLink и/или 2 сервера на 2 GPU	Вычисления	Сервер (-ы) на 4-8 GPU + NVLink и/или Сервер (-ы) на 2 GPU
Управление	Управление опционально	Управление	Сервер управления	Управление	2 сервера управления	Управление	3 сервера управления
Хранение	Хранение локально	Хранение	Хранение 1) Локально 2) Внешний S3	Хранение	Хранение 1) Локально 2) Внешний S3	Хранение	Масштабируемое хранилище объектное

S

M

L

XL

Параметры продуктовой линейки



Функция / Характеристика	S (Small)	M (Medium)	L (Large)	XL (Extra Large)
Количество узлов	1 (Модуль инференса)	2+ (Минимальный кластер)	4+ (Отказоустойчивый кластер)	10+ (Масштабируемый кластер)
Поддержка инференса	Да (локальный)	Да (кластерный*)	Да (оптимизированный)	Да (масштабируемый)
Поддержка GPU/TPU	1 GPU (опционально)	Да (несколько GPU)	Да (кластер GPU)	Да (оптимизированные фермы)
Мониторинг и метрики	Базовые метрики	Prometheus + Grafana	Расширенная аналитика	AI-аналитика + предсказания
Kubernetes (k8s) Management	Нет	Да (базовое управление)	Да (продвинутое управление)	Да (полный контроль + мониторинг)
Отказоустойчивость	Нет	Частично	Да (автовосстановление)	Да (высокая доступность)
Создание ИИ-агентов	Нет	Базовые сценарии	Да (сложные агенты)	Да (автономные агенты)
Масштабируемость	Нет	Ручное масштабирование	Да (автоматическое)	Да (гибкое + балансировка)
ИИ-ассистенты	Нет	Нет	Простые интеграции	Да (многомодальные ассистенты)
Обучение моделей	Нет	Нет	Ограничено	Да (распределённое обучение)
Целевой сценарий	Тестирование / Демо	Разработка / MVP	Продакшн (корпоративный)	AI Factory (полный цикл)

* С добавлением модуля управления, можно кластеризовать модули инференса

Примеры исполняемых задач с применением GPU платформы с NVLink



YandexGPT (LLM)



SciBox (Инструмент)



RAG (Инструмент)



CotuRe (LLM)



DeepSeek (LLM)



ValueAI (Инструмент)



Llama (LLM)



GigaChat (LLM)



Другие ИИ решения



- Анализ транзакционной сети (миллионы узлов) в режиме реального времени для выявления сложных схем мошенничества.
- Анализ кредитной истории + текстовых данных (договоры, переписка).
- Детекция аномалий в потоке транзакций (~100K TPS)
- Распознавание и верификация голоса в колл-центрах банка
- Парсинг договоров, регламентов, сканов документов и выявление рисков
- Обработка тысяч источников для прогноза волатильности рынка
- Автоматическое формирование отчетов по регуляторике на основе внутренних данных

Примеры исполняемых задач с применением типовых серверов 2RU



YandexGPT (LLM)



SciBox (Инструмент)



RAG (Инструмент)



Cotype (LLM)



DeepSeek (LLM)



ValueAI (Инструмент)



Llama (LLM)



GigaChat (LLM)



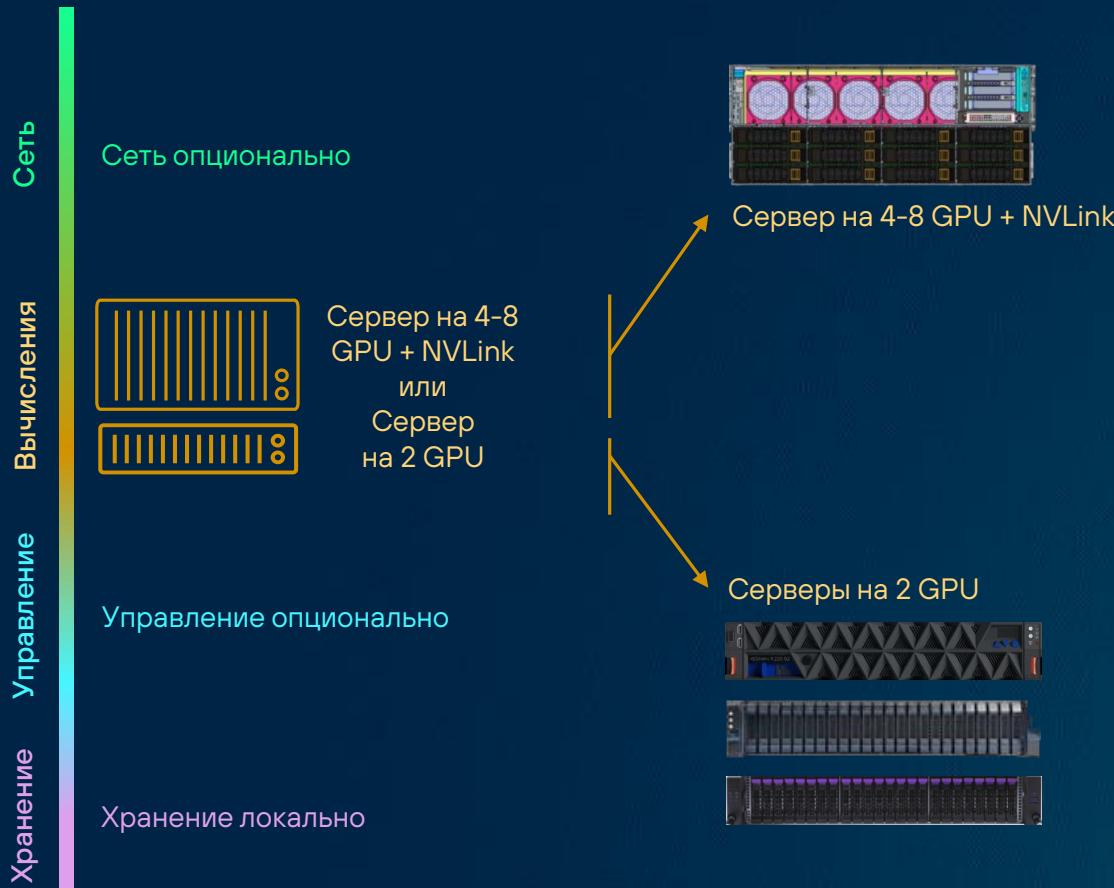
Другие ИИ решения



- Извлечение данных из документов
- Прогнозирование оттока клиентов
- Классический кредитный скоринг с фичами из транзакций.
- Выявление подозрительных транзакций (но не в реальном времени)
- Анализ клиентских профилей
- Ответы на типовые вопросы клиентов (без сложного RAG)
- Автоматическое категоризирование расходов. Разметка транзакций
- Проверка паспортов, договоров через компьютерное зрение

Инференс-узлы

тестирование/демо

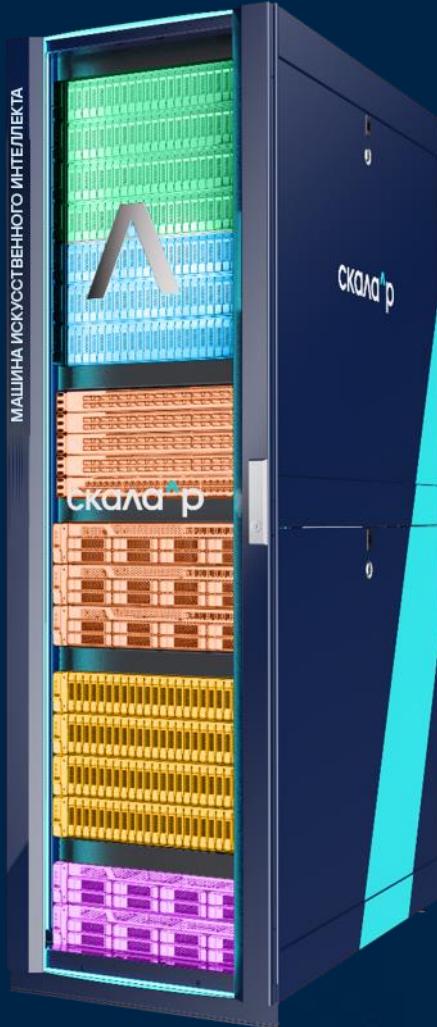


Юниты	4 RU
Процессоры	2x Intel Xeon 4/5 Gen
RAM	DDR5
PCIe слоты	Передняя панель: поддерживает максимум один слот PCIe 5.0 Задняя панель: поддерживает максимум 10 слотов PCIe 5.0 и 8 видеокарт двойной ширины
Электропитание	~3,6КВт

Юниты	2 RU
Процессоры	2x Intel Xeon 4/5 Gen
RAM	DDR5
PCIe слоты	До четырёх PCIe 5.0 x16 и до трёх PCIe 5.0 x8
Электропитание	~1,3КВт

Используемые GPU NVIDIA	NVIDIA H100	NVIDIA H200	NVIDIA A100	NVIDIA L40s	NVIDIA T4/L4
Используемые GPU Азия	16GB GDDR	32GB GDDR	48 GDDR	Аналог NVLink ограничено, PCIe 4.0 и PCIe 5.0	

Машина Скала^Ар МИИ – Модули



Модуль полезной нагрузки Машины МИИ

- Bare metal узлы, выступающие в качестве Worker нод кластера Deckhouse Kubernetes Platform. Количество этих узлов можно варьировать от 3 до 16 (в некоторых случаях возможна конфигурация от 1 узла).
- Вычислительные мощности узла – 64 физических ядра CPU, от 128ГБ до 4ТБ ОЗУ при оптимальной конфигурации памяти.
- От 1 до 8 GPU типа H100 в один узел
- Диски в этих узлах (от 4 штук в каждом узле в базовой конфигурации с возможностью масштабирования до 16 дисков на узел) можно использовать для организации хранения данных контейнеров, на сегодня это опции local path provisioner и SDS local volume в терминологии Deckhouse Kubernetes Platform.

Базовый модуль

Коммутационный модуль Машины МИИ

- Два коммутатора 100GbE или 400GbE на 32 порта(каждый) в отказоустойчивой конфигурации для сети интерконнекта Машины.
- Два коммутатора от 25GbE по 48 портов в отказоустойчивой конфигурации для организации доступа к сервисам Машины МИИ из сети заказчика.
- Два коммутатора от 25GbE на 48 портов(каждый) для организации сети хранения данных Машины.
- Два коммутатора 1GbE на 48 портов (каждый) для организации управляющей сети (out-of-band управление и in-band управление).

Модуль управления Машины МИИ

- Три сервера для размещения управляющих компонент Машины – управляющих и служебных узлов Deckhouse Kubernetes Platform, сервисов Скала^АР.
- Диски в этих узлах (по 4 штуки в каждом узле в базовой конфигурации с возможностью масштабирования до 16 дисков на узел) можно использовать для организации различных вариантов хранилищ.

Модуль хранения Машины МИИ

- Подключаемый к кластеру DKP Машины контейнерной инфраструктуры посредством CSI драйвера.
- Поддержка распределенных вычислений
- Поддерживает многопоточную загрузку/выгрузку (например, через s5cmd, rclone)

Машина Скала[®]р МИИ XL – компоненты



Коммутационный модуль Машины МИИ



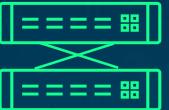
Сеть управления 1GbE
(2 x B4Com CS2148-4D)



Сеть доступа 25GbE
(2 x B4Com CS4148Q-8U)



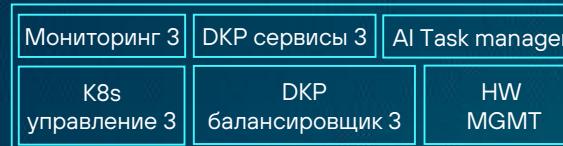
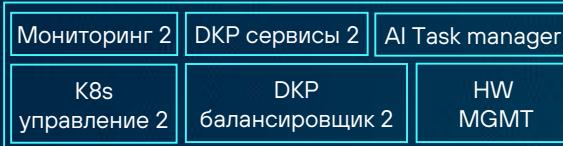
Сеть хранения данных 25GbE
(2 x B4Com CS4148Q-8U)



Сеть интерконнекта 100GbE
или 400GbE
(2 x B4Com CS4132U
или 2 x B4COM CS6132F)

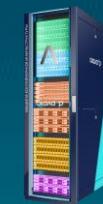
Модуль управления Машины МИИ (3 физических сервера)

Deckhouse Kubernetes Platform 1.67 CSE control plane и системные BM



Модуль хранения Машины МИИ

Система хранения данных

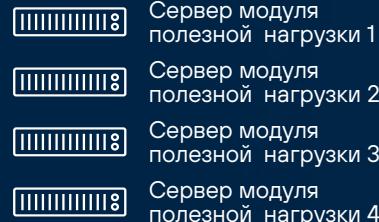


и/или

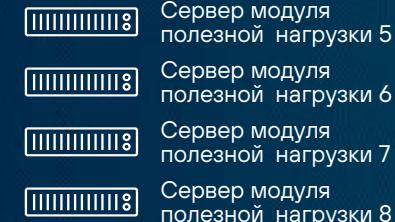
Модуль полезной нагрузки Машины МИИ (от 3 до 16 физических серверов, до 8GPU на узел)

Deckhouse Kubernetes Platform 1.67 CSE worker nodes

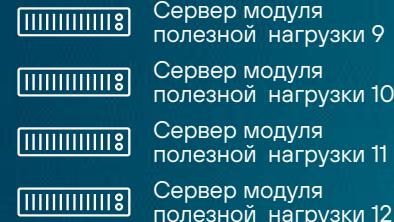
ОС Ред ОС 7.3 ФСТЭК bare metal



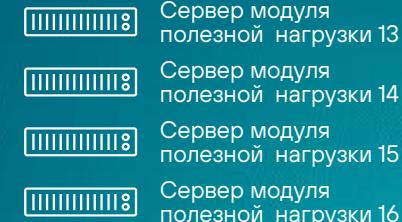
ОС Ред ОС 7.3 ФСТЭК bare metal



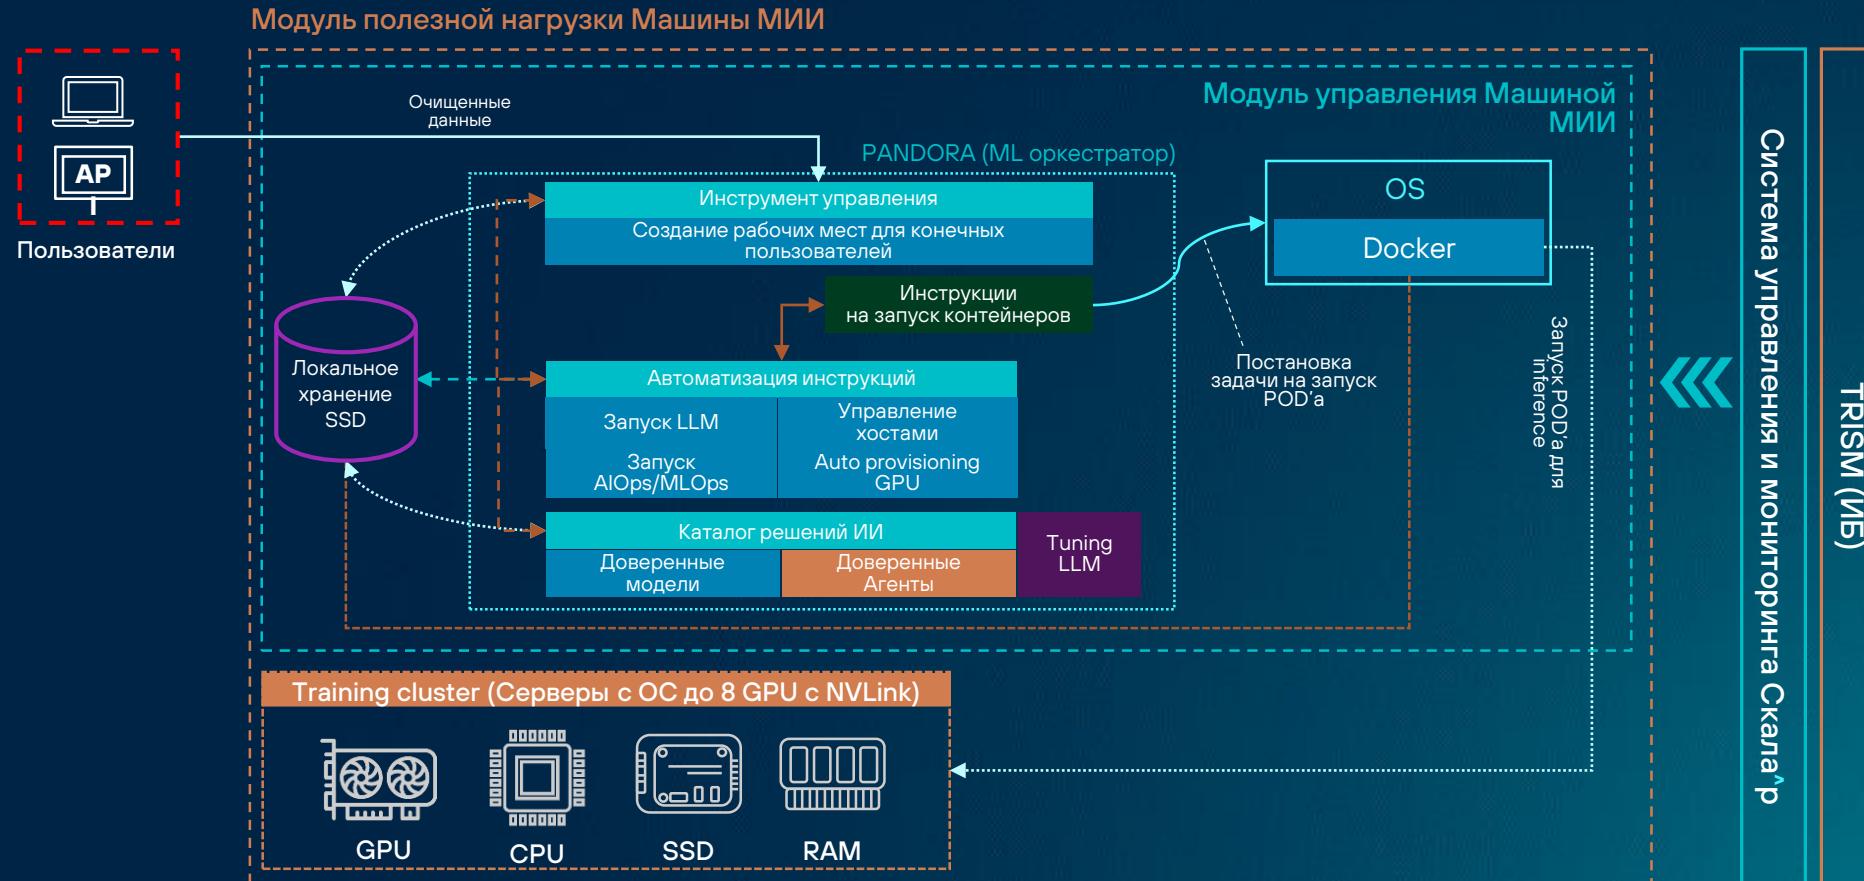
ОС Ред ОС 7.3 ФСТЭК bare metal



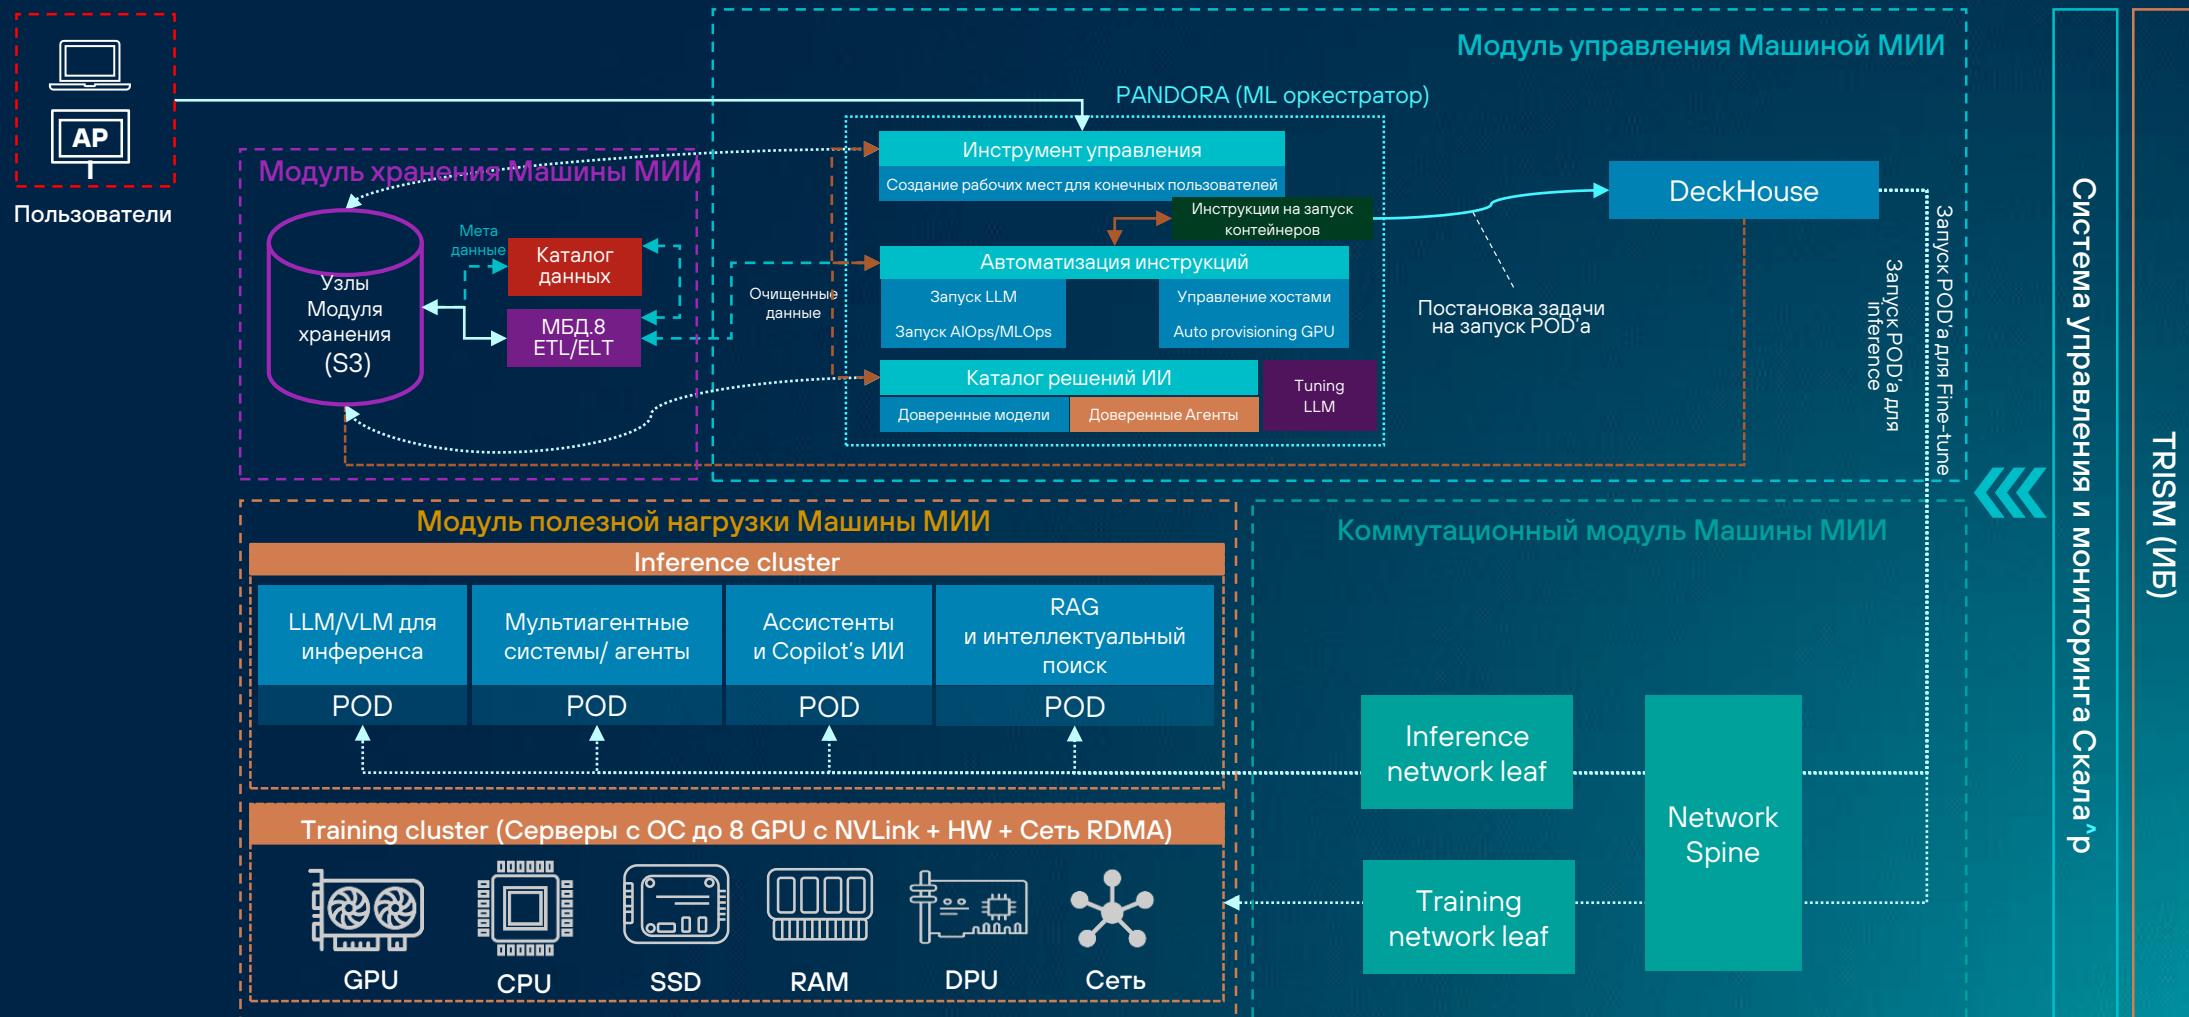
ОС Ред ОС 7.3 ФСТЭК bare metal



Машина Скала^р МИИ «S» – логическая схема



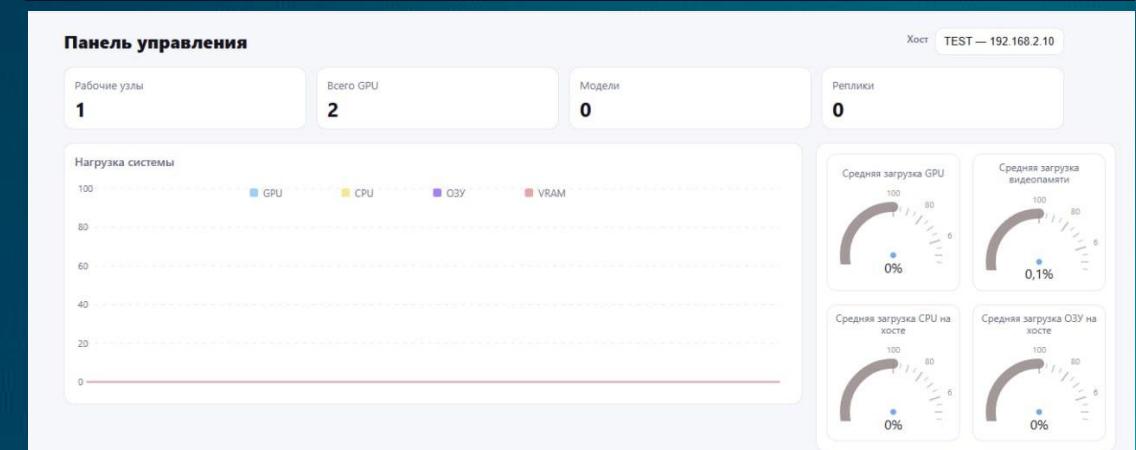
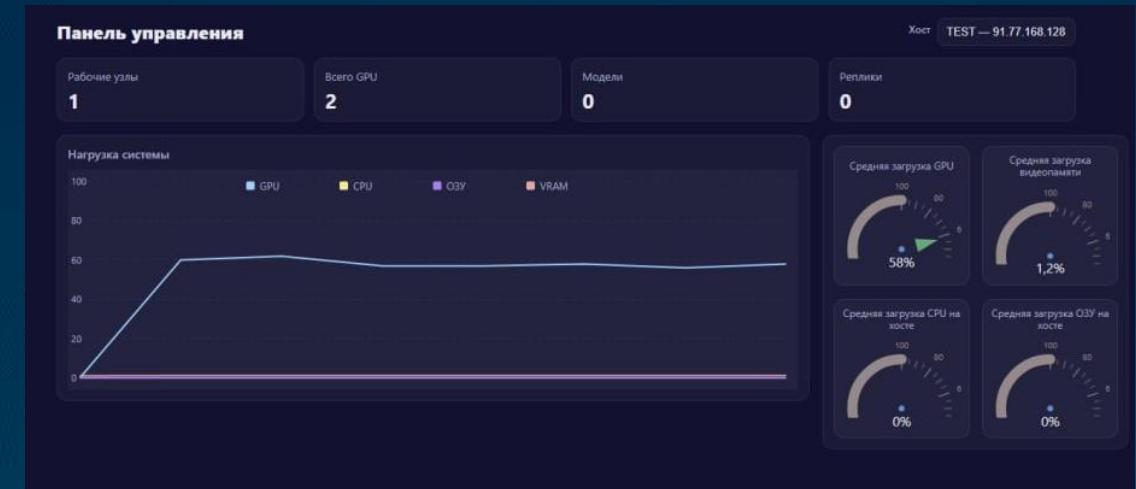
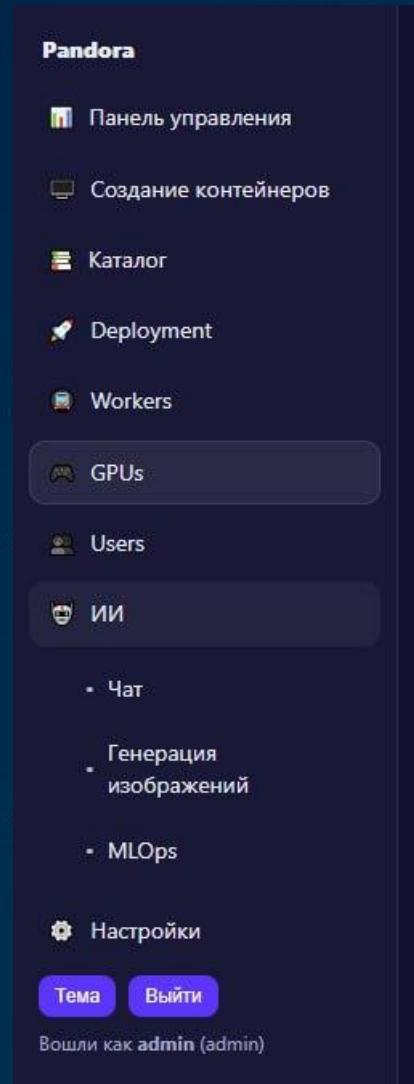
Машина Скала^р МИИ «XL» – логическая схема



PANDORA (главная страница с мониторингом)



- Мониторинг ресурсов (GPU, CPU, RAM, vRAM)
- Можно увидеть количество хостов в кластере и кол-во GPU
- Кол-во запущенных ПОДов
- Кол-во используемых токенов (всего)
- Кол-во одновременных сессий в сторону модели/моделей (RPS)
- Кол-во ассистентов/агентов ИИ
- Тёмная и белая темы везде



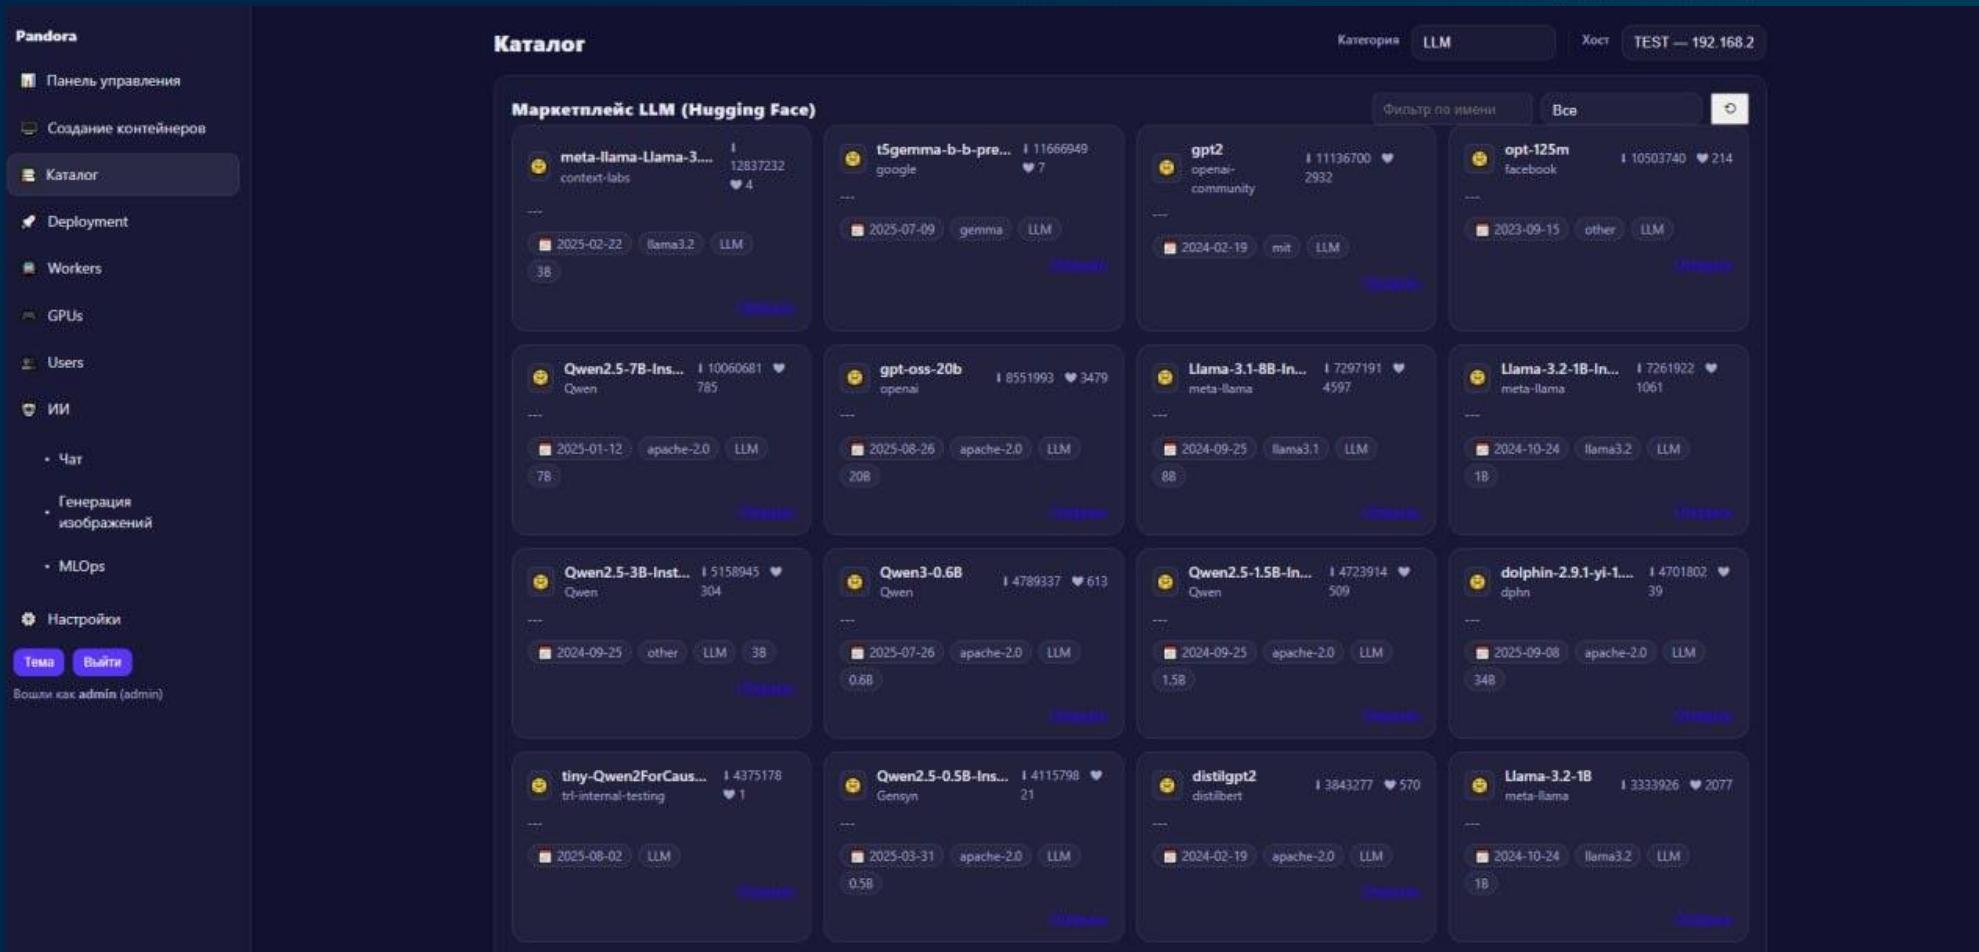
PANDORA



Создание рабочих мест с GPU ресурсами для конечных пользователей (разработчики, ML/DS-инженеры, бухгалтеры, юристы, сервисная поддержка и т.д.)

The screenshot shows the Pandora web interface. On the left, a sidebar contains navigation links: Панель управления, Создание контейнеров (selected), Каталог, Deployment, Workers, GPUs, Users, ИИ, Настройки, Тема, and Выйти. A message at the bottom says 'Вошли как admin (admin)'. The main area has a title 'Создать контейнер' (Create Container). It includes fields for Host (TEST — 91.77.168.128:2226), GPU (— без GPU —), CPU (ядра) (4), RAM (ГБ) (8), Image (Образ) (redos8-mtt-kde:latest (9.14GB)), User (Пользователь) (— выберите —), and Protocols (Protocols) (noVNC (checked), RDP, HTTP). A note says 'Порты: noVNC 6080+, RDP 3390+, HTTP 8080+ (свободные на хосте)'. A 'Запустить контейнер' (Start Container) button is at the bottom. To the right, there are three sections for existing containers: 'redos8-mtt-latest-moore_threads-084639' (running), 'nvidia-redos7-latest-nvidia-083702' (running), and 'nvidia-redos7-latest-nvidia-083428' (running). Each section has 'Подключиться' (Connect), 'Перезапуск' (Restart), 'Остановить' (Stop), and 'Удалить' (Delete) buttons.

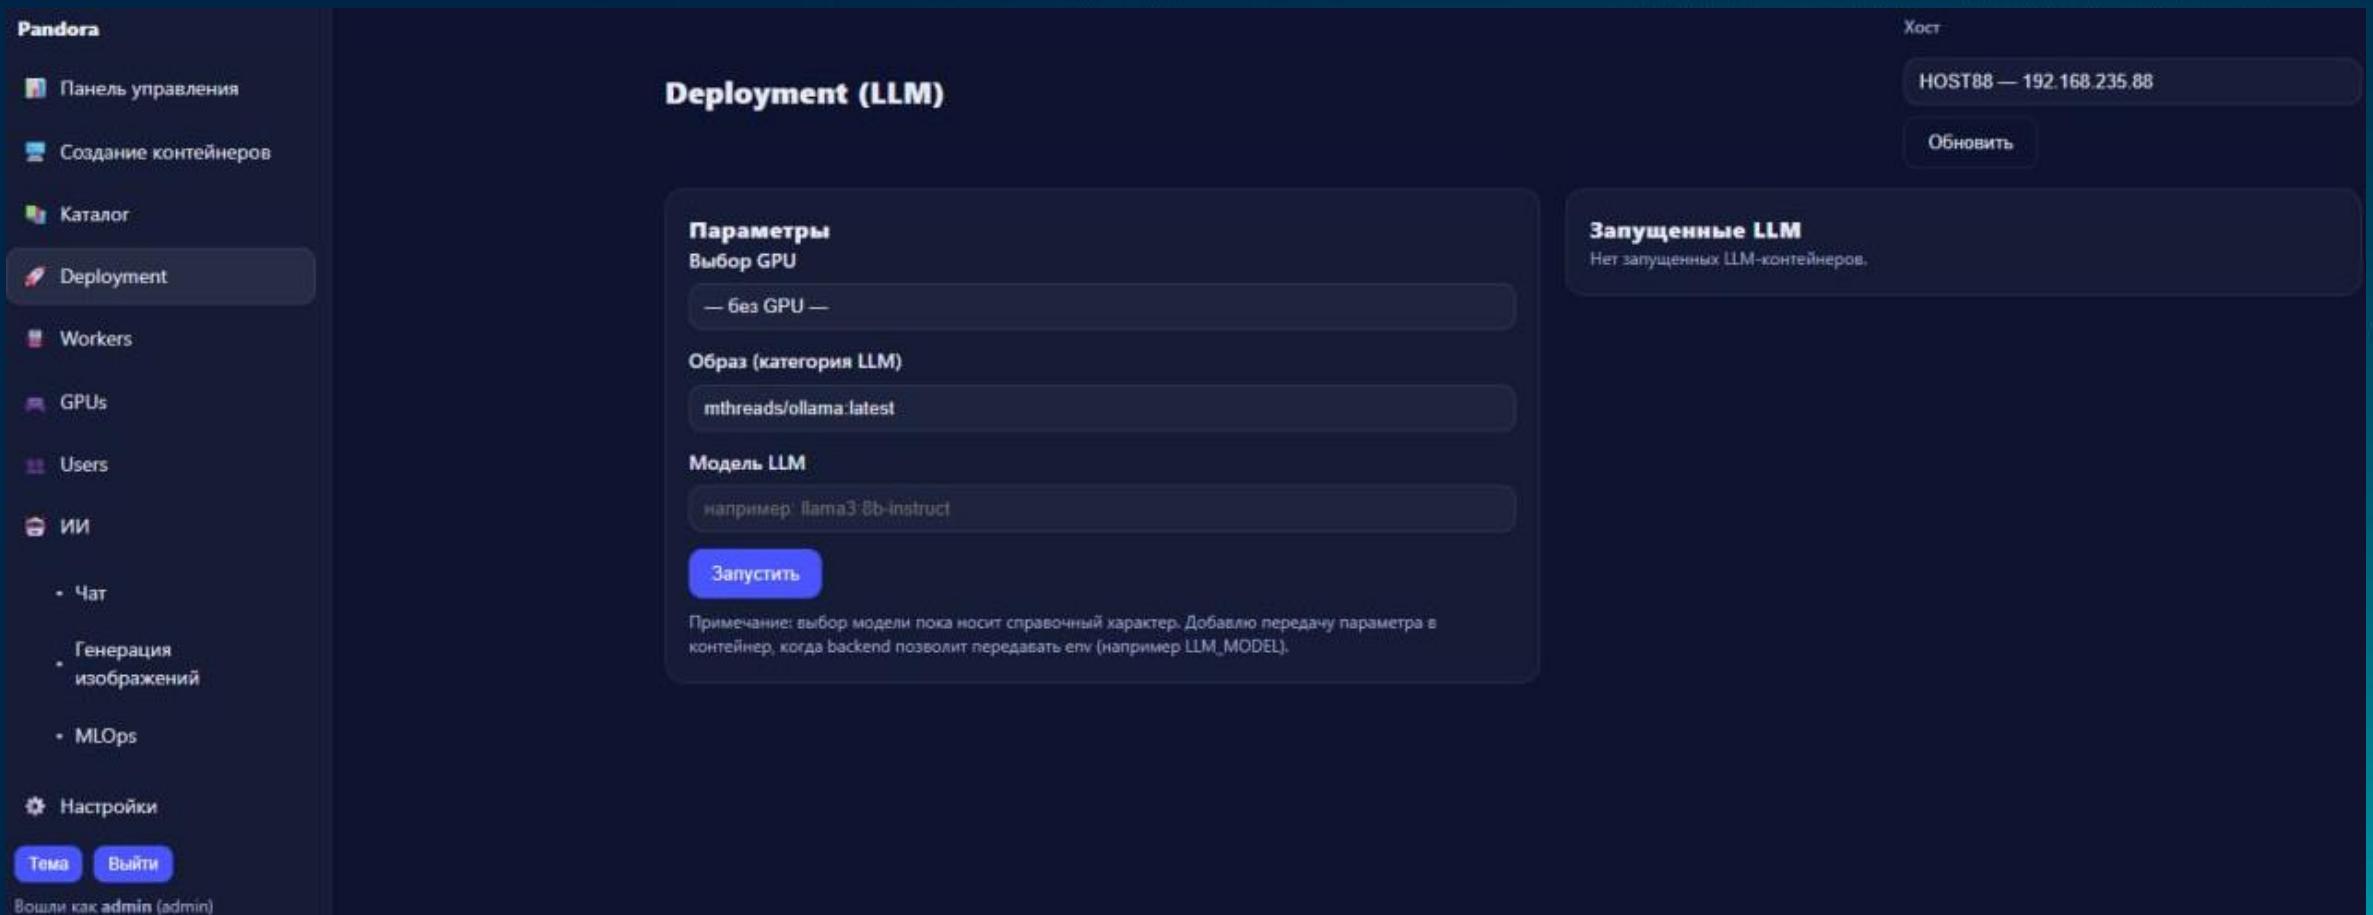
Каталог контейнеров и партнёрских решений, готовых к быстрому запуску на ПАК ИИ. Так же может пополняться решениями и разработками заказчика.



The screenshot shows the PANDORA catalog interface. On the left is a sidebar with navigation links: Панель управления, Создание контейнеров, Каталог (selected), Deployment, Workers, GPUs, Users, ИИ (selected), Чат, Генерация изображений, MLOps, Настройки, Тема, and Выйти. Below the sidebar, it says Вышли как admin (admin). The main area is titled 'Каталог' and shows a grid of 20 LLM models from the 'Маркетплейс LLM (Hugging Face)'.

Модель	Автор	Статистика	Описание
meta-llama-Llama-3...	context-labs	12837232, 4	2025-02-22, llama3.2, LLM, 38
t5gemma-b-b-pre...	google	11666949, 7	2025-07-09, gemma, LLM
gpt2	openai-community	11136700, 2932	2024-02-19, mit, LLM
opt-125m	facebook	10503740, 214	2023-09-15, other, LLM
Qwen2.5-7B-Ins...	Qwen	10060681, 785	2025-01-12, apache-2.0, LLM, 78
gpt-oss-20b	openai	8551993, 3479	2025-08-26, apache-2.0, LLM, 208
Llama-3.1-8B-In...	meta-llama	7297191, 4597	2024-09-25, llama3.1, LLM, 88
Llama-3.2-1B-In...	meta-llama	7261922, 1061	2024-10-24, llama3.2, LLM, 18
Qwen2.5-3B-Inst...	Qwen	5158945, 304	2024-09-25, other, LLM, 38
Qwen3-0.6B	Qwen	4789337, 613	2025-07-26, apache-2.0, LLM, 68
Qwen2.5-1.5B-In...	Qwen	4723914, 509	2024-09-25, apache-2.0, LLM, 158
dolphin-2.9.1-yl-1...	dphn	4701802, 39	2025-09-08, apache-2.0, LLM, 348
tiny-Qwen2ForCaus...	tri-internal-testing	4375178, 1	2025-08-02, LLM
Qwen2.5-0.5B-Ins...	Gensyn	41115798, 21	2025-03-31, apache-2.0, LLM, 58
distilgpt2	distilbert	3843277, 570	2024-02-19, apache-2.0, LLM
Llama-3.2-1B	meta-llama	3333926, 2077	2024-10-24, llama3.2, LLM, 18

Отдельный интерфейс для создания и запуска контейнера с LLM моделью на ПАК ИИ



Pandora

Панель управления

Создание контейнеров

Каталог

Deployment

Workers

GPUs

Users

ИИ

- Чат
- Генерация изображений
- MLOps

Настройки

Тема Выйти

Вошли как admin (admin)

Deployment (LLM)

Хост
HOST88 — 192.168.235.88

Обновить

Параметры

Выбор GPU
— без GPU —

Образ (категория LLM)
mthreads/llama:latest

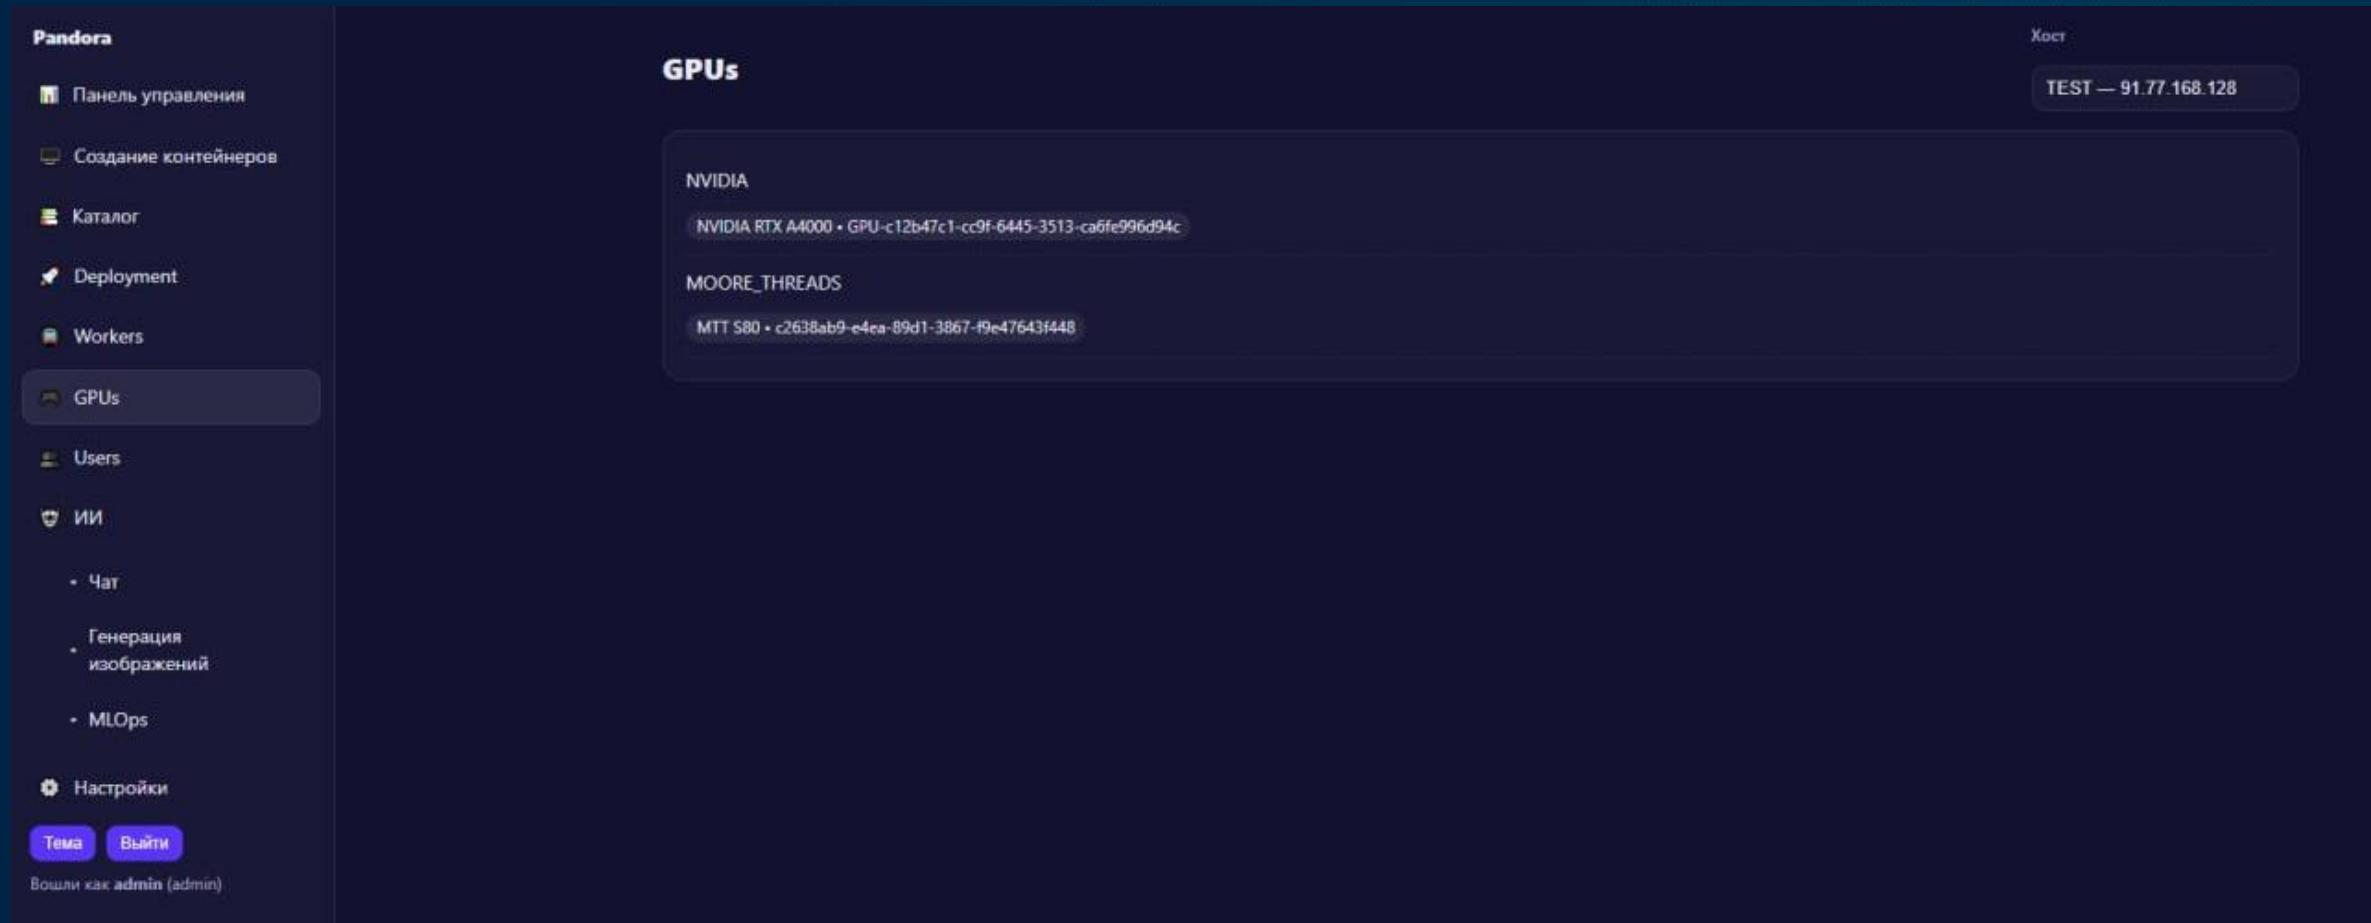
Модель LLM
например: llama3-8b-instruct

Запущенные LLM
Нет запущенных ЦМ-контейнеров.

Запустить

Примечание: выбор модели пока носит справочный характер. Добавлю передачу параметра в контейнер, когда backend позволит передавать env (например ЦМ_MODEL).

Интерфейс с представлением GPU на ПАК ИИ для хоста/блока или ПАК ИИ.



Pandora

Панель управления

Создание контейнеров

Каталог

Deployment

Workers

GPU

Users

ИИ

- Чат
- Генерация изображений
- MLOps

Настройки

Тема Выйти

Вошли как admin (admin)

Хост

TEST — 91.77.168.128

GPUs

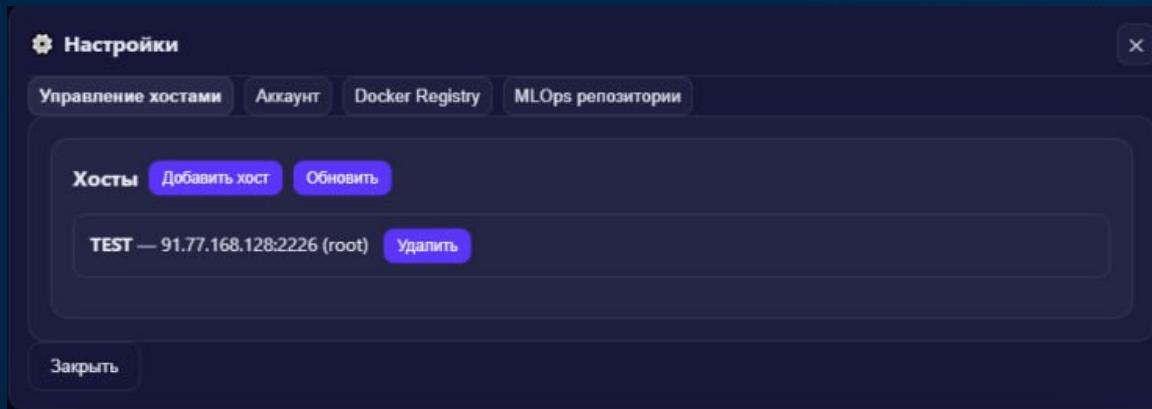
NVIDIA

NVIDIA RTX A4000 • GPU-c12b47c1-cc9f-6445-3513-caffef996d94c

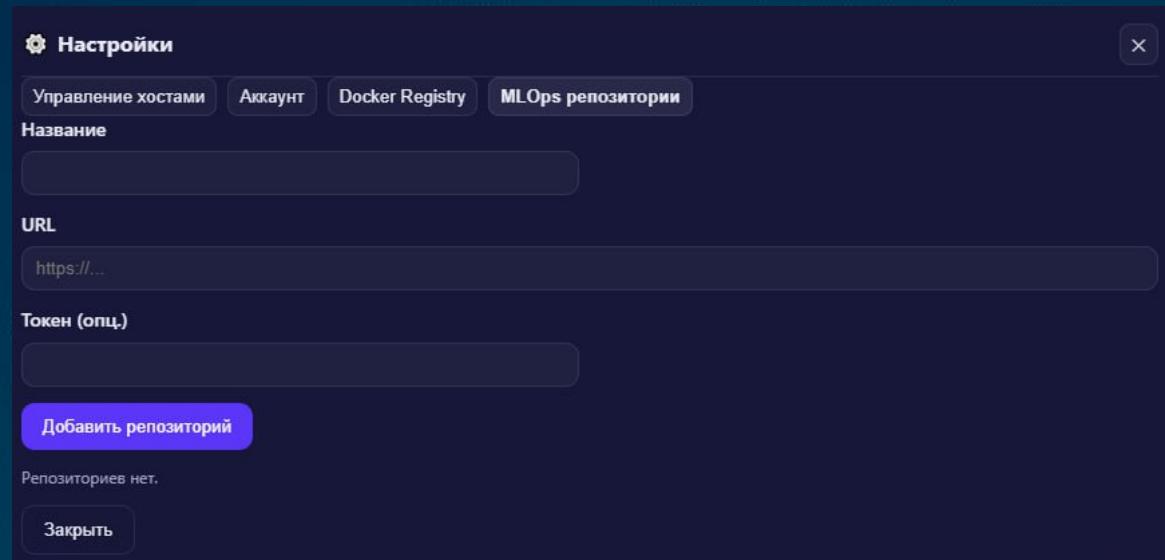
MOORE_THREADS

MTT S80 • c2638ab9-e4ca-89d1-3867-f9e47643f448

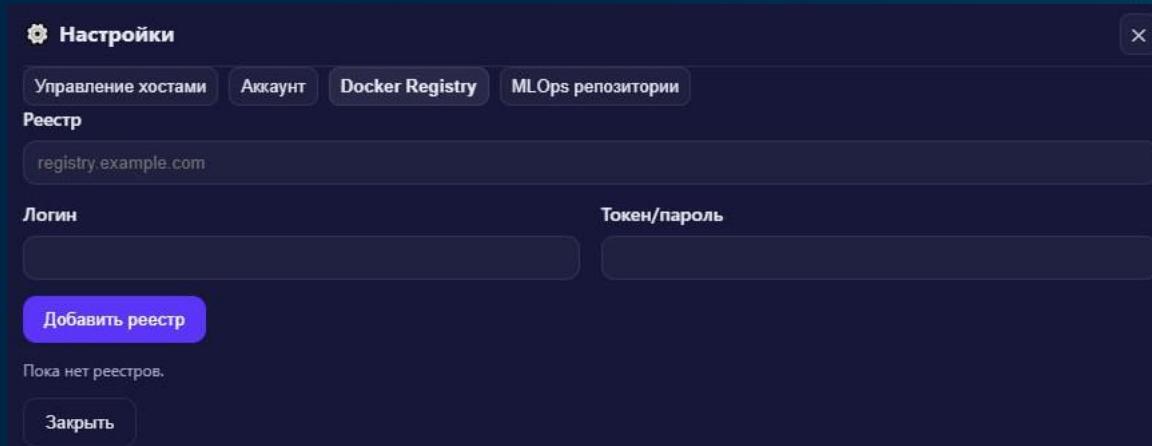
Модальное окно управления хостом (-ами)



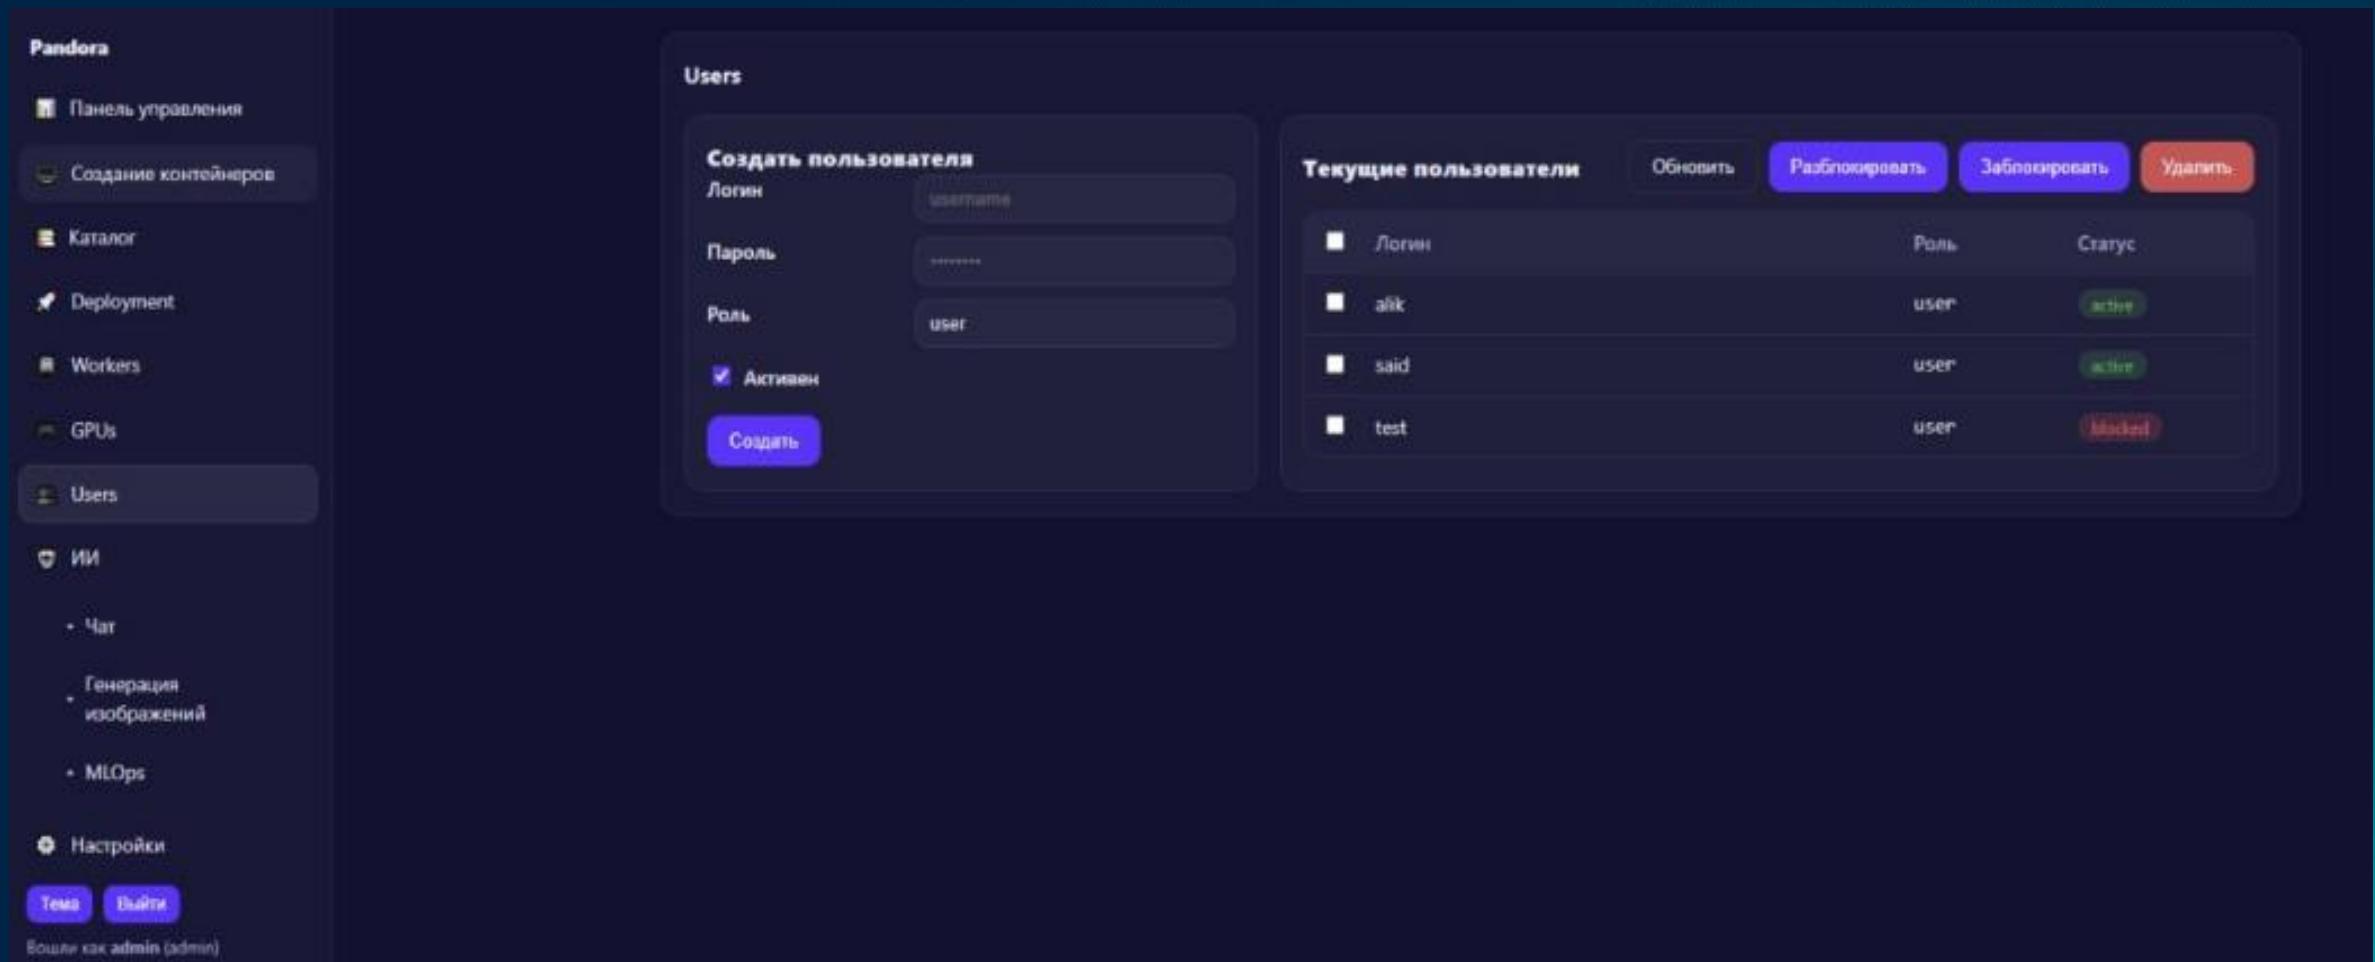
Модальное окно добавления репозиториев MLOps для LLM



Модальное окно добавления репозиториев docker



Интерфейс управления правами доступа



The screenshot displays the PANDORA web interface for managing user access. The left sidebar contains a navigation menu with the following items:

- Панель управления
- Создание контейнеров
- Каталог
- Deployment
- Workers
- GPUs
- Users** (highlighted in blue)
- ИИ
 - Чат
 - Генерация изображений
 - MLOps
- Настройки

At the bottom of the sidebar are buttons for **Тема** (Theme) and **Выход** (Logout), and the text **Вошли как admin (admin)**.

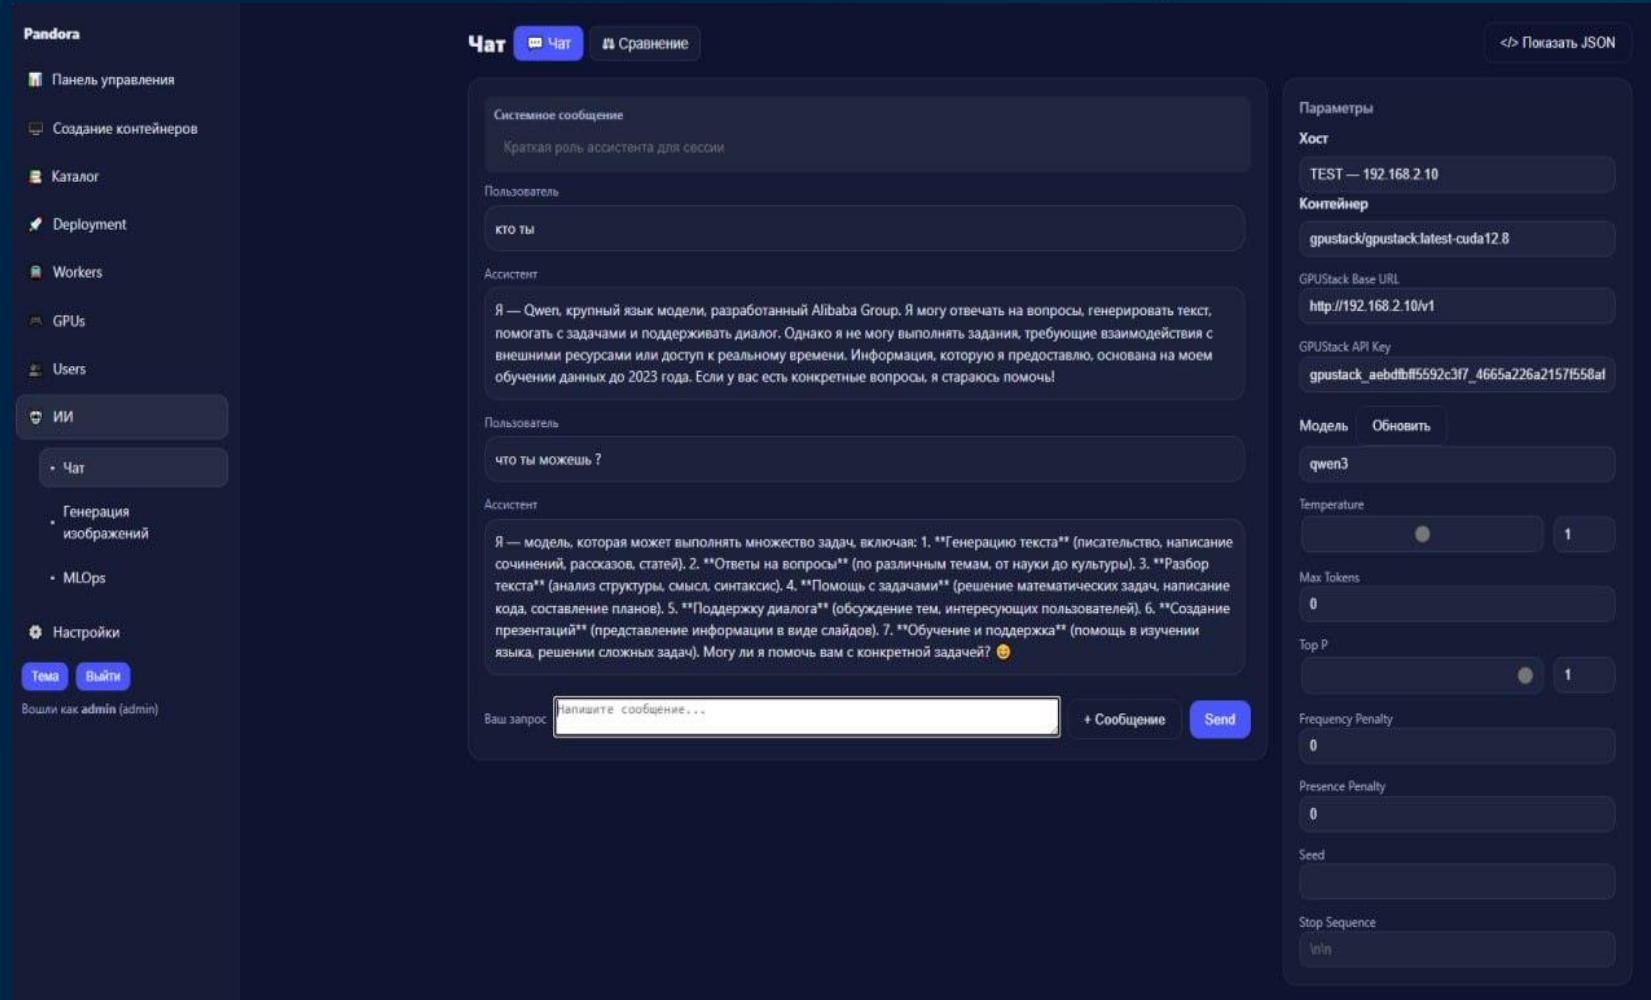
The main content area is divided into two sections:

- Users** (Left): A form for creating a new user. It includes fields for **Логин** (Login) with placeholder "username", **Пароль** (Password) with placeholder "password", **Роль** (Role) set to "user", and a **Активен** (Active) checkbox which is checked. A **Создать** (Create) button is at the bottom.
- Текущие пользователи** (Right): A table listing existing users. The columns are **Логин** (Login), **Роль** (Role), and **Статус** (Status). The table data is as follows:

Логин	Роль	Статус
alik	user	active
said	user	active
test	user	disabled

At the top of the right section are buttons for **Обновить** (Update), **Разблокировать** (Unlock), **Заблокировать** (Lock), and **Удалить** (Delete).

Интерфейс работы с развёрнутой LLM на хосте/модуле/ПАК ИИ , а так же Fine-tune модели



The screenshot displays the PANDORA web interface, specifically the Chat tab. The left sidebar shows various sections: Панель управления, Создание контейнеров, Каталог, Deployment, Workers, GPUs, Users, ИИ (selected), Генерация изображений, MLOps, Настройки, Тема (selected), and Выйти. The top navigation bar includes Чат (selected), Чат, Сравнение, and Показать JSON.

Системное сообщение: Краткая роль ассистента для сессии.

Пользователь: кто ты

Ассистент:

Я — Qwen, крупный язык модели, разработанный Alibaba Group. Я могу отвечать на вопросы, генерировать текст, помогать с задачами и поддерживать диалог. Однако я не могу выполнять задания, требующие взаимодействия с внешними ресурсами или доступ к реальному времени. Информация, которую я предоставляю, основана на моем обучении данных до 2023 года. Если у вас есть конкретные вопросы, я стараюсь помочь!

Пользователь: что ты можешь ?

Ассистент:

Я — модель, которая может выполнять множество задач, включая: 1. **Генерацию текста** (писательство, написание сочинений, рассказов, статей). 2. **Ответы на вопросы** (по различным темам, от науки до культуры). 3. **Разбор текста** (анализ структуры, смысла, синтаксис). 4. **Помощь с задачами** (решение математических задач, написание кода, составление планов). 5. **Поддержку диалога** (обсуждение тем, интересующих пользователей). 6. **Создание презентаций** (представление информации в виде слайдов). 7. **Обучение и поддержка** (помощь в изучении языка, решении сложных задач). Могу ли я помочь вам с конкретной задачей? 😊

Ваш запрос: Напишите сообщение...

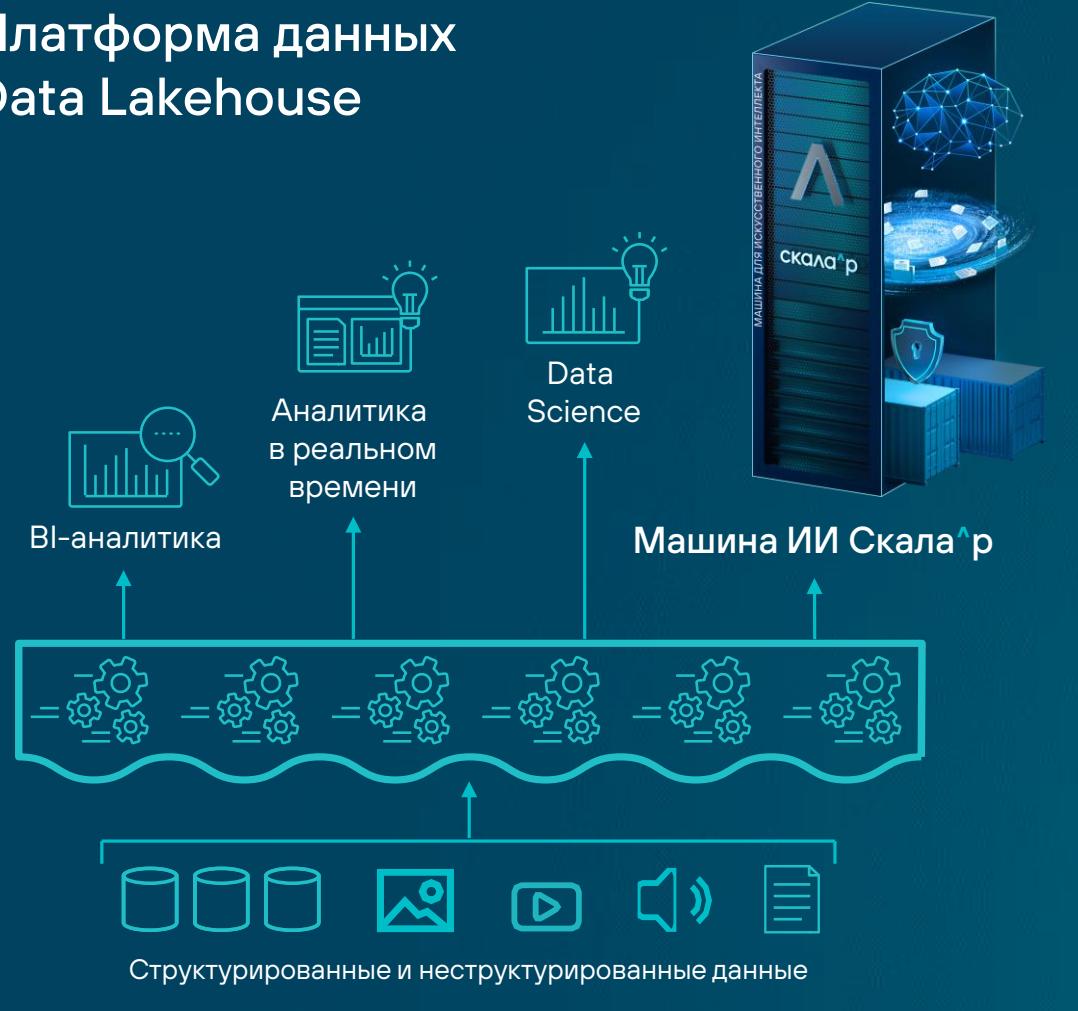
Параметры:

- Хост:** TEST — 192.168.2.10
- Контейнер:** gpustack/gpustack:latest-cuda12.8
- GPUStack Base URL:** http://192.168.2.10/v1
- GPUStack API Key:** gpustack_aebdbbf5592c3f7_4665a226a2157f558a1
- Модель:** Обновить (qwen3)
- Temperature:** 1
- Max Tokens:** 0
- Top P:** 1
- Frequency Penalty:** 0
- Presence Penalty:** 0
- Seed:**
- Stop Sequence:** \n\n

Экосистема данных Lakehouse + ML/AI



Платформа данных Data Lakehouse



Единое управление данными

объединяет структурированные и неструктурированные данные для обучения моделей ИИ, поддерживая разнообразные рабочие нагрузки (например, BI, ML, генеративный ИИ)

Расширенные возможности для ИИ

применение инновационных форматов с поддержкой транзакционности и версионирования, гарантии надёжности данных для ИИ

Масштабируемость и производительность

оптимизировано для крупномасштабного использования ИИ с инструментами, поддерживающими аналитику в реальном времени

Управление и безопасность

качество данных и соответствие требованиям для приложений ИИ

Интеграция генеративного ИИ

обеспечивает инновационные варианты использования, такие как агенты и системы рекомендаций

Примеры использования ИИ для корпоративных задач*



1 Совершенствование процессов технической поддержки продуктов компании IT.ONE

Автономная [система для классификации, маршрутизации](#) поступающих [обращений клиентов](#) по разным каналам связи на корректную линию технической поддержки.

Построена на основе обработки естественного языка с применением адаптированных языковых моделей LLM.

2 Повышение эффективности клиентского сервиса

Чат-бот [технической поддержки клиентов](#) для информирования, ответов на общие вопросы, уточнения дополнительной информации.

Построен на основе технологии обработки естественного языка и дообученных языковых моделях LLM.

3 Совершенствование внутренних процессов по повседневной работе сотрудников

Расшифровка [аудиозаписей](#) встреч с суммаризацией итогов, определения решений и поручений по аудиозаписи: на основе обработки естественного языка, транскрибация, применение адаптированных языковых моделей LLM.

5 Повышение эффективности разработки и тестирования программных продуктов компании

Чат-бот [для разработчиков и тестировщиков](#), с поддержкой [используемых языков программирования с учетом кодовой базы клиентских продуктов](#) (ПО) во внутреннем контуре компании.

Создание изолированной ИТ-инфраструктуры для эксплуатации результатов инициатив ИИ.

4 Создание единого связанного пространства данных из разнородной информации документов ограниченного доступа, приходящих в ответ на запросы контролирующих органов государственной власти федерального уровня

Автономное (on-premise) ИИ-решение на основе LLM, в формате ПАК для автоматического извлечения данных из неструктурированных документов и автоматического формирования фабулы документа с гибкой настройкой правил извлечения данных.

6 Повышение эффективности процессов управления проектами компании

Интеллектуальный помощник (чат-бот), повышающий [эффективность повседневной работы](#) руководителей проектов с внутренней документацией, базой знаний и регламентами компании, хранящимися в разнородных внутренних корпоративных сервисах компании.

Построен на основе адаптированных языковых моделей LLM, интеллектуального алгоритма для контекстного поиска, агрегации данных и предоставления структурированных ответов через интуитивный интерфейс чата.

7 Формирование у сотрудников компетенций, позволяющих использовать доверенные технологии ИИ

Средства обучения сотрудников промпт-инжинирингу и мотивации использования ИИ на основе.

Построены на больших фундаментальных языковых моделях (облачных) для выполнения текущих задач.

8 Совершенствование процессов подбора сотрудников

Система скрининга соискателей на соответствие требованиям позиции (вакансии).

Построена на основе технологий NLP и применения адаптированных языковых моделей LLM.

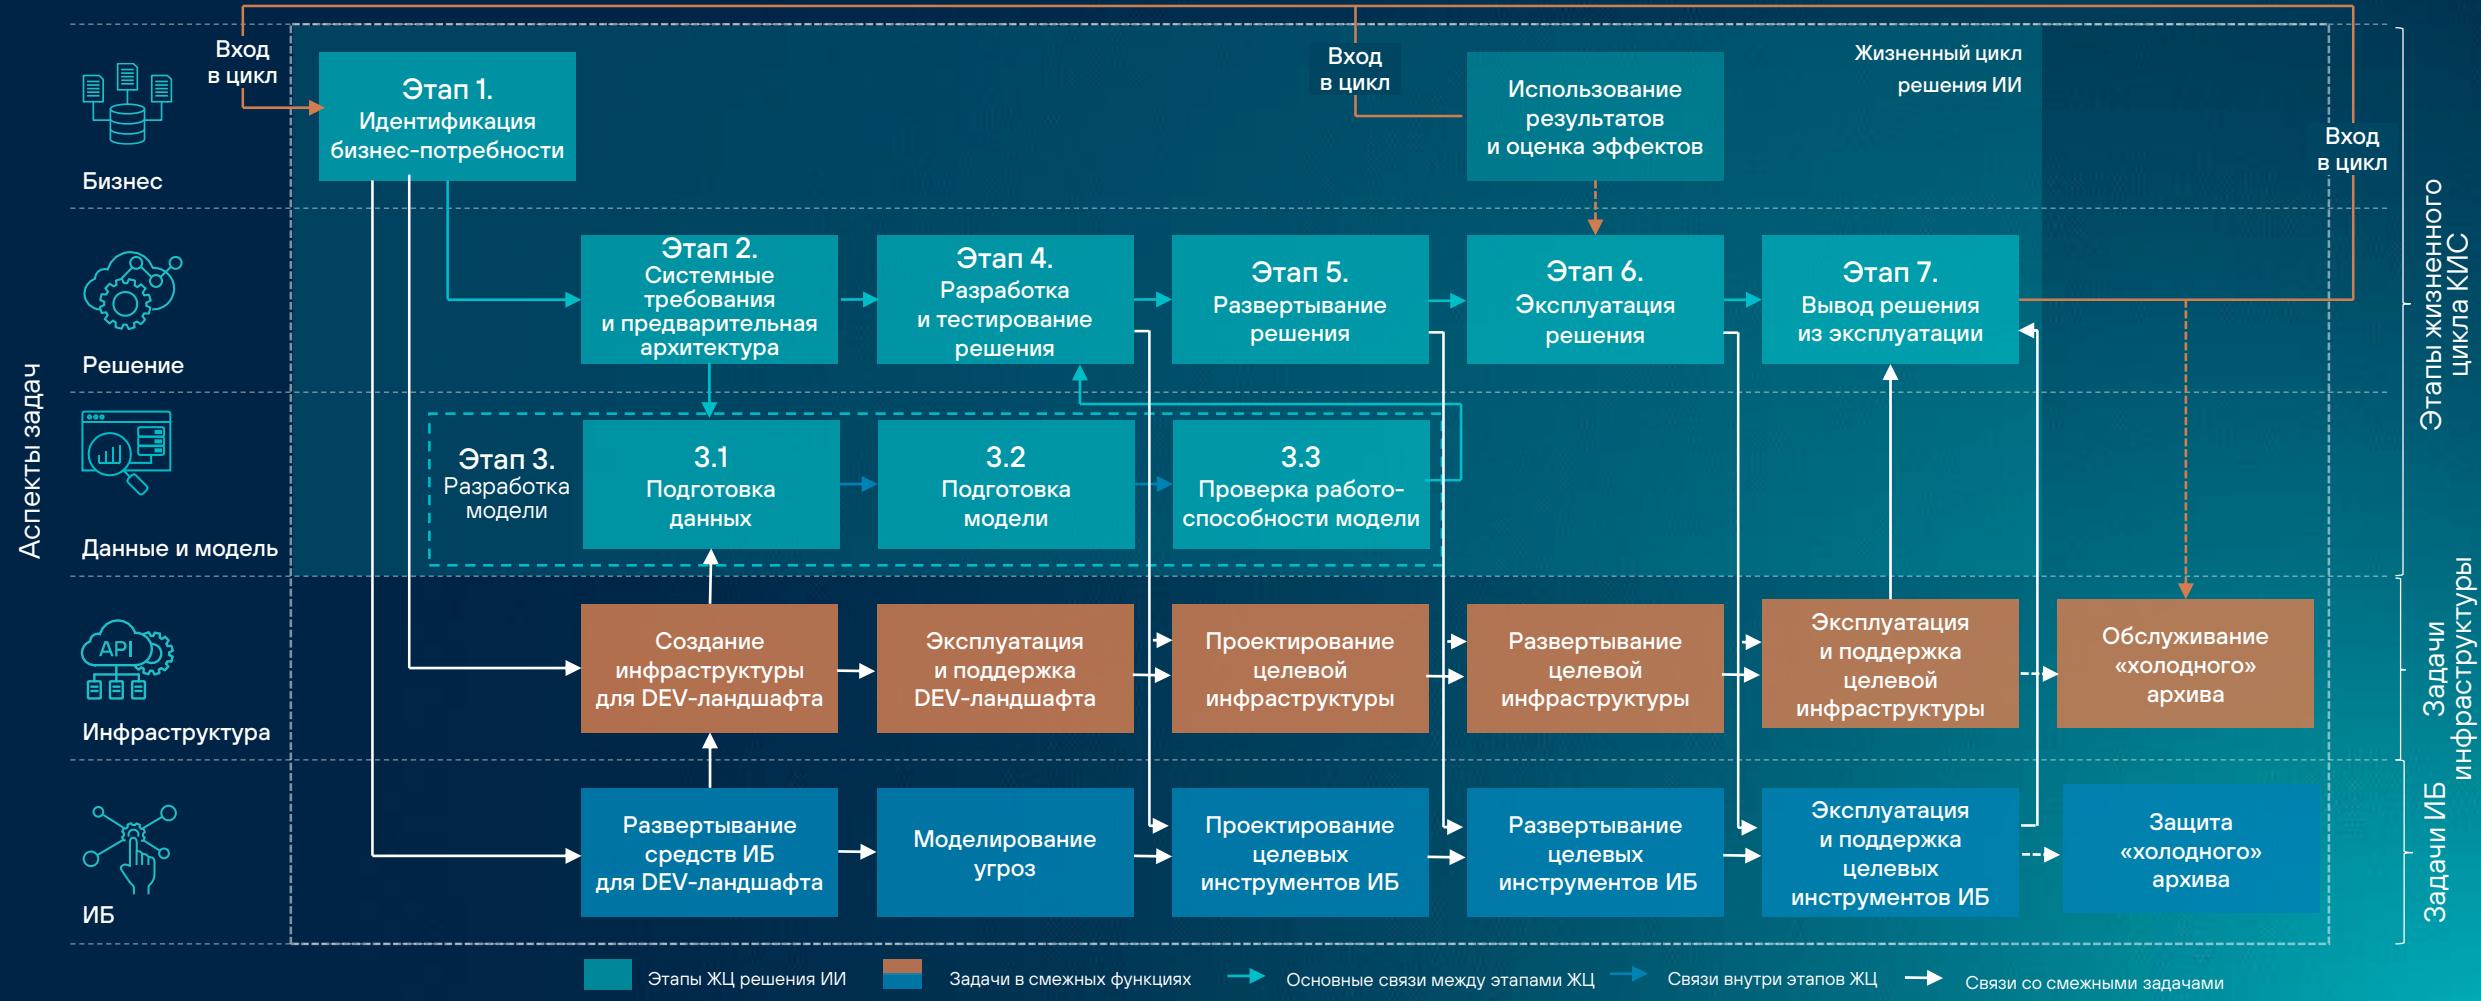
* Типовые задачи для инфраструктуры Машины ИИ Скала[®]

Жизненный цикл КИС с ИИ



Общий взгляд на этапы и задачи

Современный жизненный цикл КИС с ИИ имеет специфические черты, связанные с работой с данными и моделями и тесную связь с задачами инфраструктуры и ИБ

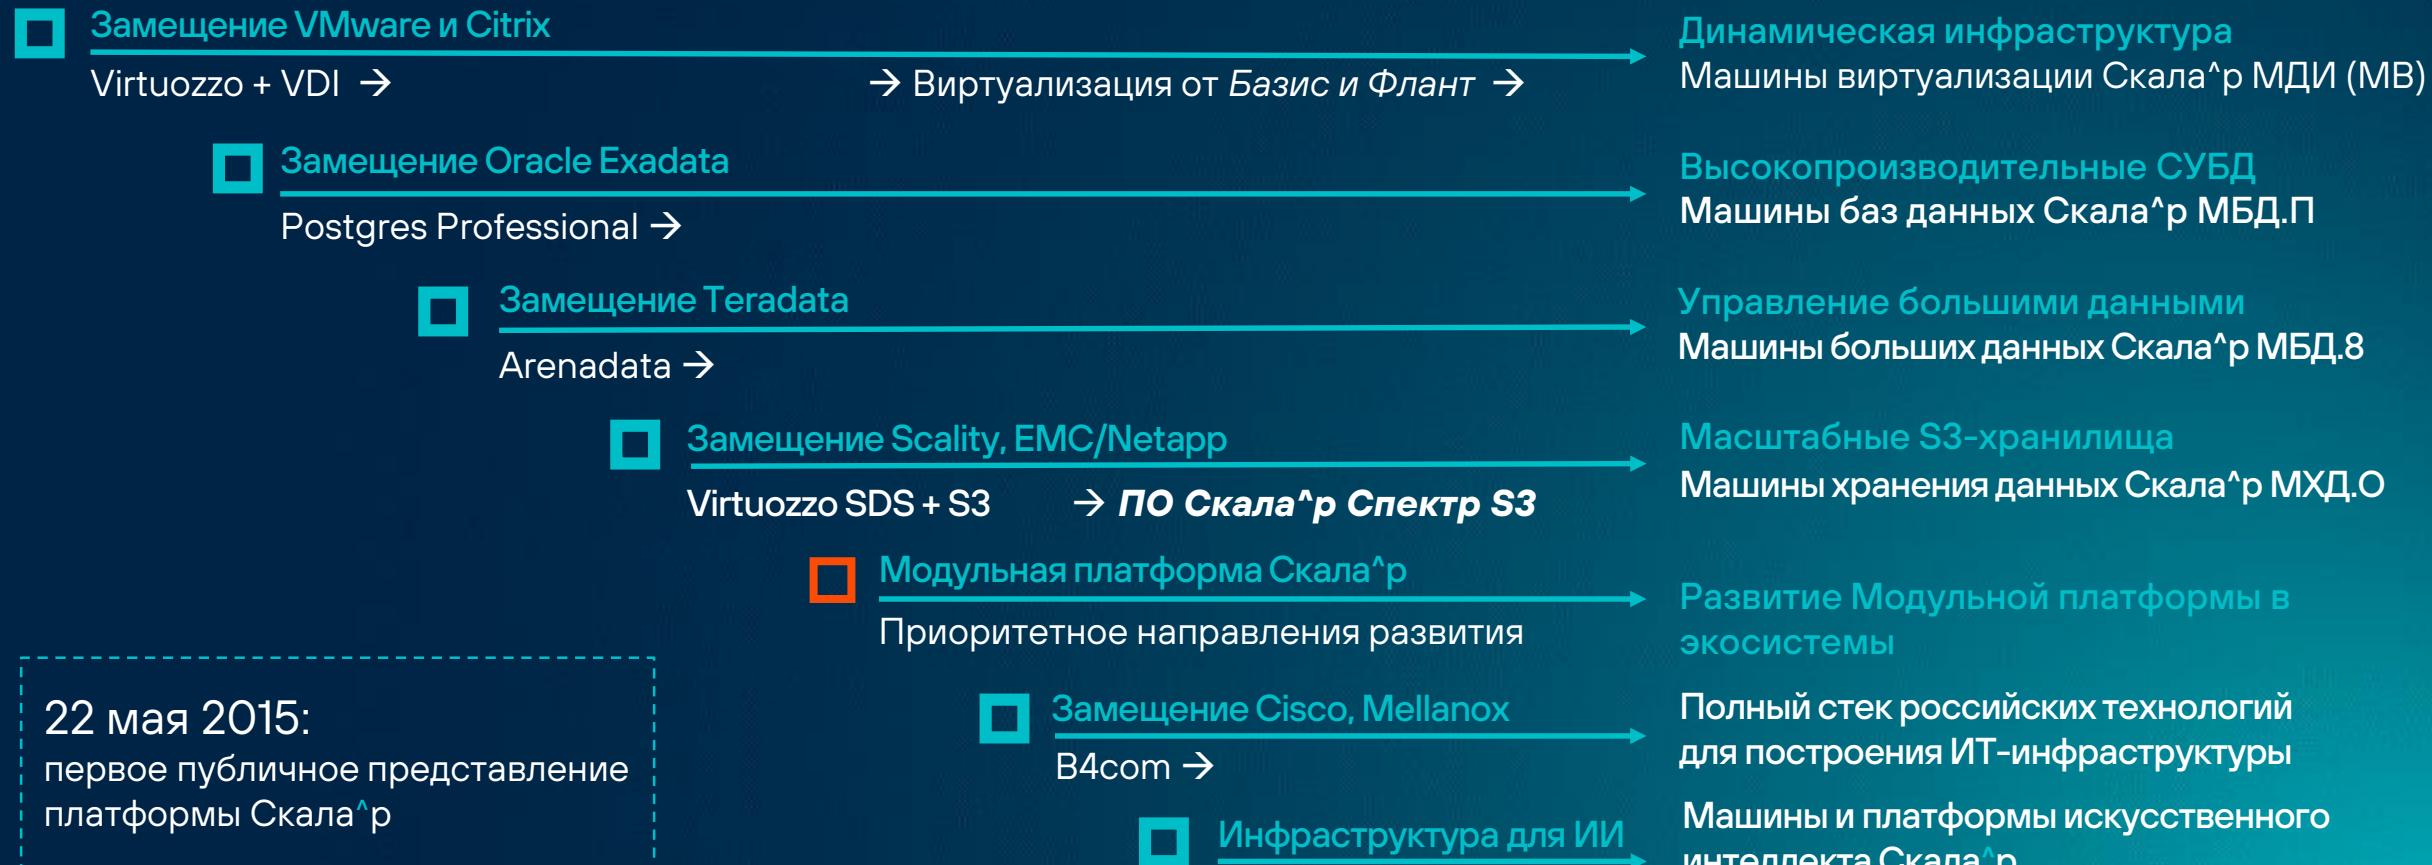


История и технологического развития Скала^р



От импортозамещения Highload-стека к доверенной ИТ-инфраструктуре на ПАК

2014-2015 2016 2017 2019 2021 2023 2025





Спасибо за внимание!



www.skala-r.ru