



conews
FORUM





Сложность **vs** Доступность:

Как облако демократизирует
искусственный интеллект

Михаил Соколов



Мировой рынок расходы на ИИ

млрд \$

988

2024

1479

2025

2023

2026

интересно

×10

0,3 Вт

энергоёмкость стандартного
поискового запроса Google

VS

3,0 Вт

энергоёмкость
поискового запроса ChatGPT



Развитие инфраструктуры



Интеграция
в потребительскую
электронику



AlaaS – ИИ как услуга

Стремительный рост ИИ → драйвер рынка видеокарт



млрд \$

20,2

23,6

2024

2025

18,2%
CAGR до 2032

Операторы дата-центров
наращивают мощности

- ⚡ Обучение больших языковых моделей (LLM)
- ⚡ Поддержка ресурсоемких ИИ-приложений
- ⚡ Инференс

Сценарии использования



 Персонализированное клиентское обслуживание

 Запуск сложных AI-продуктов и исследований

 Обработка и извлечение данных из документов

 Ускорение разработки и аналитики

 Сквозная автоматизация бизнес-процессов

 Прогнозирование и предиктивная аналитика

Проблемы внедрения инфраструктуры с ИИ



Очень дорогое «железо» —
необходимы значительные
вложения в инфраструктуру
(On-premise)



Для оптимизации языковых
моделей необходимы
дополнительные
капитальные вложения

Преимущества облачных сервисов



Быстрый
запуск

Экономическая
эффективность

Масштабируемость





Тренд



ИИ рядом


Вызовы географической
распределенности

 турбо_облако

качество доступа

Геораспределенная
платформа

Q1 2026



Создание инфраструктурных сервисов для продуктов AI/ML



→ Потребность рынка
в вычислениях на GPU

82

клиентских запроса в '22-'23
на 1000+ GPU разных классов

→ У большинства облачных
игроков продукты
с GPU уже запущены

Предпосылки

2024

- Предоставление вычислительных мощностей на базе GPU из облака с возможностью выбора оптимальной конфигурации: ML, 3D, VDI
- Создание MVP сервисов AI/ML

Инициатива

Анализ опыта запуска GPU



Клиентам нужны
не «сырые» GPU,
а виртуализированные
и преднастроенные
для работы среды

Выводы

2025 →

- ✓ Созданную инфраструктуру с GPU масштабируем
- ✓ Запускаем новый сервис «Виртуальные машины с GPU»
- ✓ Разворачиваем высокоуровневые сервисы для ML/AI

Сервисы

Сервисы для AI



Продукт	Серверы BareMetal	Виртуальная инфраструктура	Inference	Foundation models	Нейрошлюз
Формат	Выделенный физический сервер с GPU	ВМ или контейнер с GPU	Виртуальный инстанс	ML модель	Чат с ИИ-моделями для бизнес-пользователей
Тариф	За конфигурацию сервера	За виртуальные ресурсы	За инстансы	За токены	За пользователя
Доступно	от 150 340 ₽ / мес	от 11 900 ₽ / мес	Скоро	Скоро	Скоро

Что выбрать



Производительность
GPU

Гибкое управление
конфигурацией

Минимальные
накладные расходы

Изоляция от «шума»

Минимальная
стоимость

BareMetal



Виртуальная
машина



Linux
контейнеры



Выделенные серверы BareMetal



Без виртуализации для ресурсоемких задач, включая серверы с графическими картами для нейросетей, работы с графикой и машинного обучения

- Современные конфигурации серверов
- Широкий выбор операционных систем
- Инструменты для удаленного управления сервером
- Единый портал управления облаком и серверами BareMetal
- Аппаратное резервирование компонентов сервера
- Возможна доукомплектация базовой конфигурации
- Поддержка NVLink
- Нет переподписки по PCIe
- Доступна поддержка функционала виртуальных дисков

 Сетевая связанность с облачной инфраструктурой

 В составе сервера могут быть предоставлены GPU-карты

Выделенные серверы BareMetal



	Сервер Medium	Сервер Medium Plus	Сервер Medium Pro	Сервер Medium Ultra	Сервер Large GPU
CPU	AMD EPYC 7313 32 ядра, 3.0 GHz	Intel Xeon Gold 6240 36 ядер, 2.6 GHz	AMD EPYC 7443 48 ядер, 2.85 GHz	Intel Xeon Gold 6248R 48 ядер, 3.0 GHz	AMD EPYC 7543 64 ядра, 2.8 GHz
RAM	от 256 ГБ	от 512 ГБ	от 512 ГБ	от 1024 ГБ	от 512 ГБ
Хранение	SAS / SATA / NVMe SSD	SATA / SAS / SSD	SAS / SATA / NVMe SSD	SATA / SAS / SSD	SAS / SATA / NVMe SSD
Кол-во GPU	До 1-й на сервер	До 2-х на сервер	До 2-х на сервер	До 2-х на сервер	До 8-ми на сервер
Поддерживаемые GPU	L4, A6000	L4, A6000, A100	L4, L40S, A6000, A100, H100	L4, A6000, A100	L4, L40S, A6000, A100, H100
+Комплектация RAM, HDD, SSD	Да	Да	Да	Да	Да

Виртуальная инфраструктура с GPU



Позволяет делиться ресурсами физического GPU между несколькими VM или контейнерами, обеспечивая гибкость и эффективность без владения дорогостоящим оборудованием

- Выделенный профиль GPU на каждую VM/контейнер
- Отдельный образ для Data Science с популярными инструментами и фреймворками
- Масштабирование в пару кликов
- Инструменты для удаленного управления VM
- Подготовленные образы с оптимизацией под GPU
- Возможность заказа VM и контейнера с несколькими GPU
- Современное железо с DDR5 и PCIe Gen5
- Единый портал управления

 TensorFlow, PyTorch и другие инструменты для вашей работы

 Гарантированная производительность без влияния «шумных соседей»

Конфигурации виртуальных машин с GPU



	Профиль 1	Профиль 2	Профиль 3	Профиль 4	Профиль 5	Профиль 6	Профиль 7
GPU	L4	L4	L4	L4	L40S	L40S	L40S
Профиль GPU	3 ГБ	6 ГБ	12 ГБ	24 ГБ	12 ГБ	24 ГБ	48 ГБ
vCPU, ядра	4	8	16	32	8	16	32
RAM	16 ГБ	32 ГБ	64 ГБ	128 ГБ	48 ГБ	96 ГБ	192 ГБ
SSD	60 ГБ	60 ГБ	60 ГБ	60 ГБ	60 ГБ	60 ГБ	60 ГБ


Конфигурации Linux-контейнеров с GPU



	Профиль 1	Профиль 2	Профиль 3	Профиль 4	Профиль 5
GPU	H200	H200	H200	H200	H200
Профиль MIG	1g.35gb	2g.35gb	3g.71gb	4g.71gb	7g.141gb
vCPU	14	14	28	28	56
RAM	64 ГБ	64 ГБ	128 ГБ	128 ГБ	256 ГБ
SSD	60 ГБ	60 ГБ	60 ГБ	60 ГБ	60 ГБ

Новые сервисы

2026



 турбо_облако

50+

облачных
сервисов

облако высоких скоростей

 **SaaS**
Бизнес-приложения



 **PaaS**
Платформенные
сервисы



 **IaaS**
Виртуальная
инфраструктура и сеть



 **Информационная
безопасность**



 **Профессиональные
сервисы**



скоро

Нейро-
шлюз

Public preview — Q1 2026

Private Preview — уже сейчас



Онлайн-платформа, где можно
работать с множеством средств
и сервисов AI в едином
рабочем пространстве


— 1

 **турбо_облако**

скоро

**Inference
platform**

Public preview – Q1 2026




**Позволяет создавать инстансы
с необходимыми библиотеками
и инструментами для гибкого
управления ML-моделями**

—2

скоро

Foundation
models

Public preview — Q2 2026



Сервис обеспечивает доступ
к актуальным ML-моделям,
расположенным на доверенной
инфраструктуре провайдера,
с тарификацией по токенам

—3

БЫСТРЫЙ
СТАРТ С ТУРБО



Соколов
Михаил



Turbo
Cloud.ru