

**Hardware and software solutions by RSC: “Govorun”
supercomputer refresh 2024-2025.**

Alexander Moskovsky, CEO and co-founder

GRID 2025, JINR, Dubna

7 July 2025

15+ years of innovations for HPC, Data Centers and AI compute infrastructure

Development of innovative energy-efficient compute, storage, and software solutions delivering unique features and addressing specific end-user needs

About RSC Group

Leading innovative HPC solution provider in Russia/CIS and EMEA

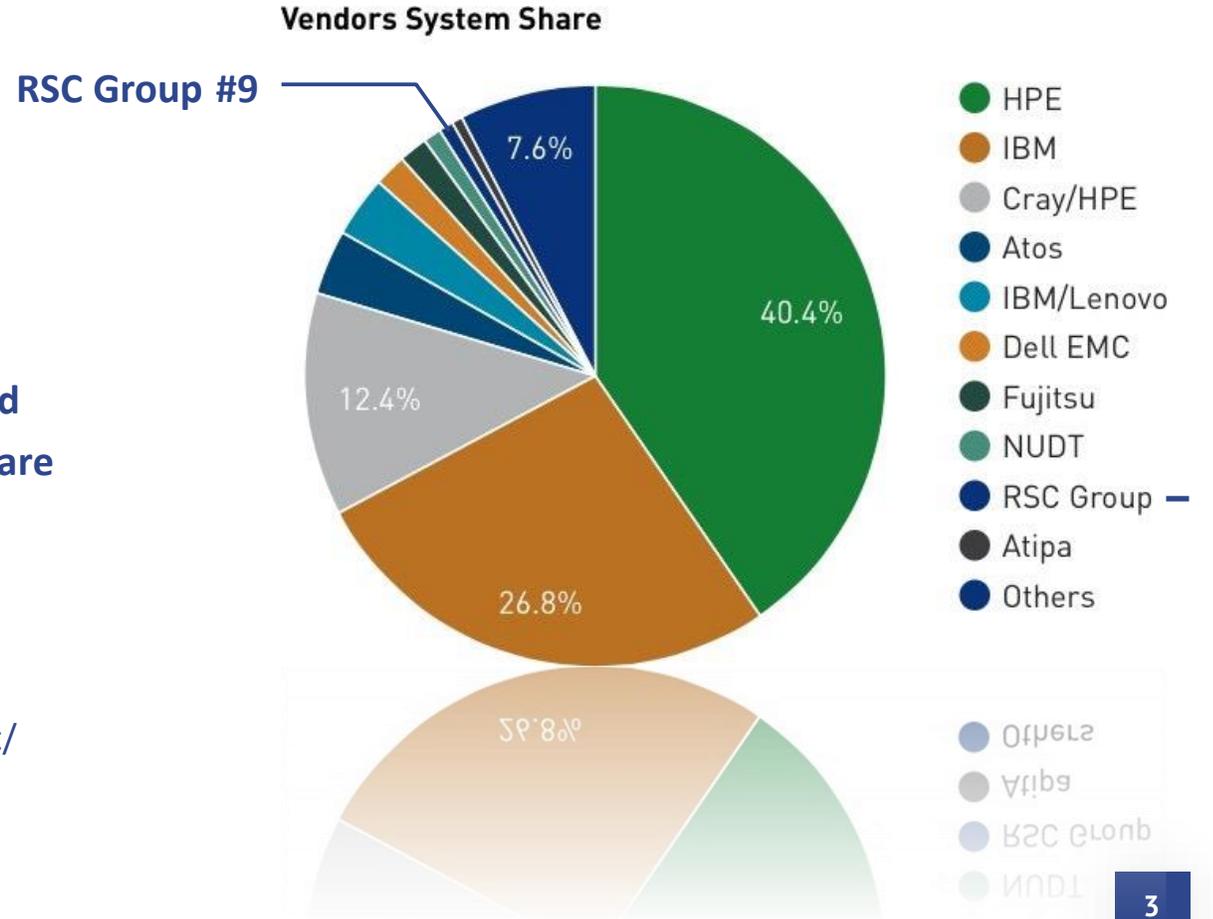


«Best IT-solution for Data Center» nomination at Russian DC Awards 2020



The only Russian company ranked in Top10 HPC Vendors System Share by Top500 (Nov 2014)*

* Top10 suppliers by market volume <https://www.top500.org/statistics/list/>



Strong Market Position

Leading innovative HPC solution provider in Russia/CIS and EMEA



Joint Institute for Nuclear
Research

The most
energy efficient
system in Russia



Over **70%**
of all Russian
systems in HPCG
rating

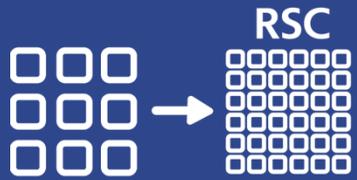


4 of RSC systems –
the only Russian
systems in **IO500**
rating

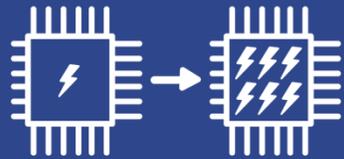


- **24%**
- share in
Russian
Top50 rating

HPC. Points Of Excellence



Computing
Density



Power
Density



Energy
Efficiency



Ease to manage
and maintain

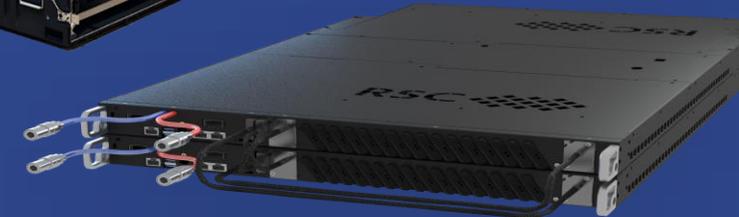


Reliability

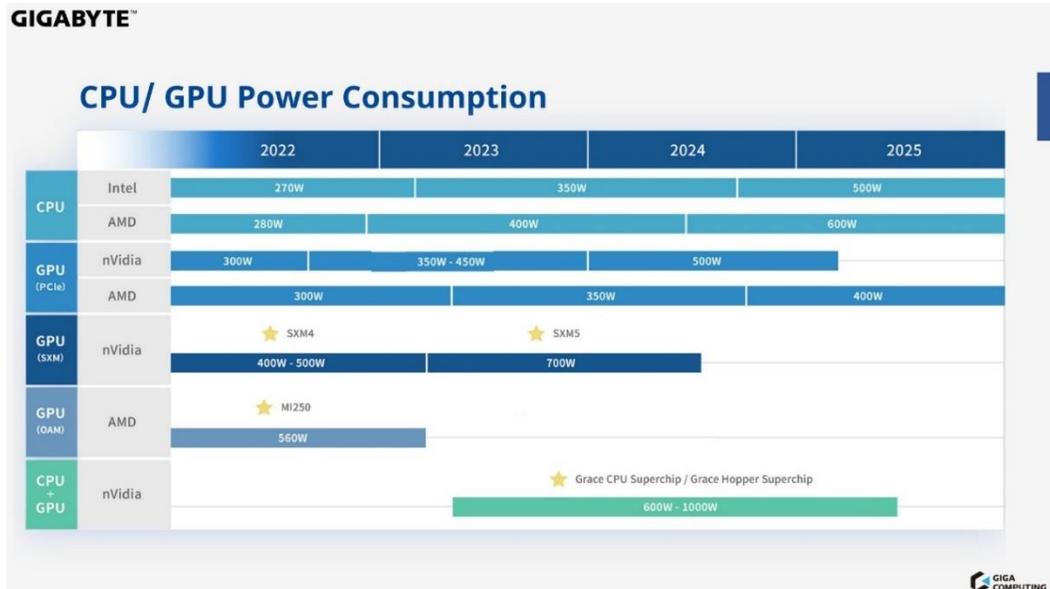
State-of-the-Art & Turn-Key Solutions:



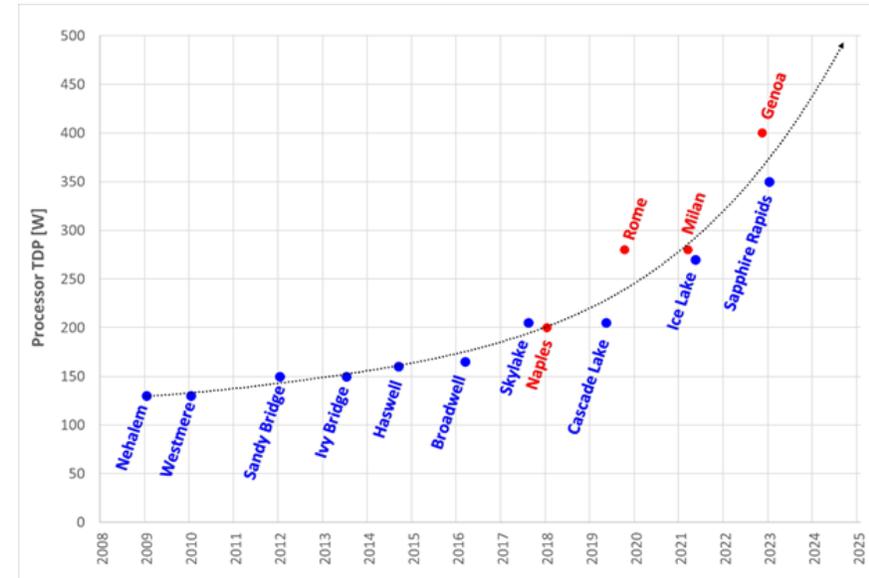
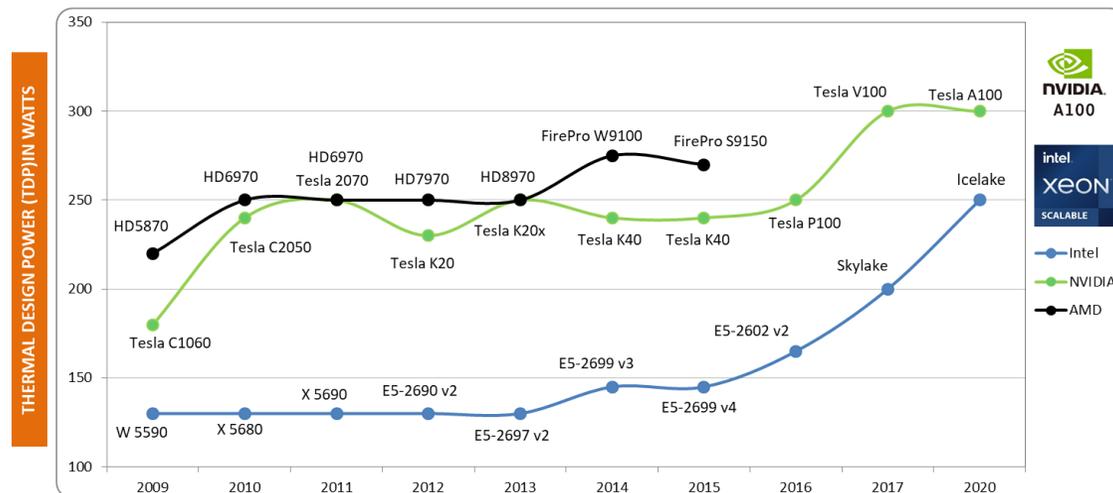
- **Energy-Efficient Supercomputers**
- **High Performance Computing**
- **Data Centers**
- **Edge Computing**
- **AI Compute Infrastructure**
- **Intellectual Data Storage Systems**
- **Integrated Data Center Management Software**



CPU/GPU power consumption is growing fast



GPU and CPU TDP TREND



Liquid cooling in Top20@Top500 rating

Большинство самых мощных систем из списка Top500 используют жидкостное охлаждение

Top500 Rank	System	Cooling technology
1	El Capitan	Direct cold water cooling
2	Fugaku	Direct cold water cooling
3	Aurora	Direct cold water cooling
4	JUPITER Booster	Direct warm water cooling
5	Eagle	Airflow cooling
6	HPC6	Direct cold water cooling
7	Fugaku	Direct cold water cooling
8	Alps	Direct cold water cooling
9	LUMI	Direct cold water cooling
10	Leonardo	Direct warm water cooling

Top500 Rank	System	Cooling technology
11	Isambard-AI phase 2	Direct cold water cooling
12	Tuolumne	Direct cold water cooling
13	ISEG2	Direct cold water cooling(?)
14	MareNostrum 5 ACC	Direct warm water cooling
15	ACBI 3.0	Direct warm water cooling
16	Eos NVIDIA DGX SuperPOD	Direct cold water cooling
17	Discovery 6	Direct cold water cooling
18	SCC-24	Direct warm water cooling
19	Venado	Direct cold water cooling
20	Sierra	Direct cold water cooling

Возможно ли охладить воздухом стойку 100 кВт?

При увеличении плотности набивки ИТ-стойки увеличивается внутреннее сопротивление потоку воздуха. Электрическая мощность вентилятора пропорционально кубу его производительности.

МОЩНОСТЬ ИТ-СТОЙКИ, кВт	ПЕРЕПАД ТЕМПЕРАТУРЫ, °С	ТЕМПЕРАТУРА ВХОД / ВЫХОД, °С	РАСХОД ВОЗДУХА, М ³ /ЧАС	ПОТЕРИ ДАВЛЕНИЯ ВНУТРИ СЕРВЕРА, Па	МОЩНОСТЬ ВЕНТИЛЯТОРОВ, кВт	МОЩНОСТЬ ИТ, кВт	СООТНОШЕНИЕ МОЩНОСТИ, %
15	15	25 / 40	2 994	50	0,10	15	0,7
30	15	25 / 40	5 988	200	0,83	29	2,8
60	15	25 / 40	11 976	800	6,65	53	11,1
100	15	25 / 40	19 960	2222	30,80	69	30,8
100	12	40 / 52	24 950	3472	60,16	40	60,2

* Выполнен оценочный расчет

Интегрированный подход: адаптивность на разных уровнях

Уровень	Средства адаптации
Прикладное ПО	Модели программирования, средства разработки
Связующее ПО (Промежуточное ПО)	Конфигурации под задачу Оркестратор (РСК БазИС)
Аппаратные платформы	Программно-определяемые конфигурации
Инженерная инфраструктура	Агенты мониторинга, управления

Наука

- **Объединенный институт ядерных исследований (ОИЯИ)**
- Российская академия наук (МСЦ РАН)
- Физико-технический институт имени Иоффе РАН
- Институт математики имени Соболева СО РАН
- Сибирский суперкомпьютерный центр (ИВМиМГ СО РАН)
- Институт океанологии имени Ширшова
- Институт физики атмосферы им. А. М. Обухова РАН
- Гидрометцентр России

Образование

- Санкт-Петербургский политехнический университет Петра Великого (СПбПУ)
- Московский государственный университет имени Ломоносова (МГУ)
- Нижегородский государственный университет (ННГУ)
- Южно-Уральский государственный университет (ЮУрГУ)
- Московский физико-технический институт (МФТИ)

Отрасли экономики

- VK Social Media Corp.
- Авиастроение
- Автомобилестроение
- Энергетика
- Компьютерная графика
- Нефте- и газодобыча
- и другие

Решение «РСК Экзастрим ИИ» для развития вычислительной инфраструктуры ИИ

5th phase Govorun modernization

2024-2025 гг.



**2 новых узла
«РСК Экзастрим ИИ»
(8 карт Nvidia H100 в каждом)**

**2 новых узла хранения
RSC Tornado AFS (2x1 ПБ)**

**Прирост производительности
416 Тфлопс (37%)**

**Суммарная
производительность системы
2,2 ПФлопс**

Compute node "RSC Exastream AI"

Конфигурация серверов «РСК Экзастрим ИИ»,
установленных в ОИЯИ:

- высота узла **2U**,
- **два процессора Intel Xeon Platinum 8468** (4-го поколения, 48 ядер, тактовая частота 2,1-3,8 ГГц, объем кэш-памяти 105 МБ),
- **8 графических ускорителей NVidia H100** (PCIe, 80 ГБ),
- **1 ТБ** оперативной памяти,
- **16 ТБ** емкости хранения данных на базе SSD-дисков с интерфейсом NVMe,
- **4 блока питания** производства РСК,
- **система прямого жидкостного охлаждения** разработки РСК.



Inside «RSC Exastream AI»



Сервер «PCK Экзастрим ИИ» 2U: 208/408 TFLOPS (FP64/TF64) до 2 ТБ ОЗУ, до 128 ТБ SSD

21 сервер в шкафу «PCK Экзастрим» 42U: 4,368/8,568 PFLOPS (FP64/TF64), 115 кВт на шкаф

Вычислительный узел «РСК Экзастрим ИИ»


- Графические карты с прямым жидкостным охлаждением (до 8 ГПУ) попарно объединены мостами на базе технологии высокоскоростных соединений NVLink для обеспечения быстрой передачи данных между графическими процессорами.
- Имеет локальную подсистему хранения «теплых данных», сетевую подсистему с доступом на основе технологии GPUDirect.
- Реализована возможность расширения ресурсов путем подключения дополнительных пар GPU или системы внешнего хранения данных на базе пула твердотельных дисков (JBOD), подключаемой напрямую к серверу.



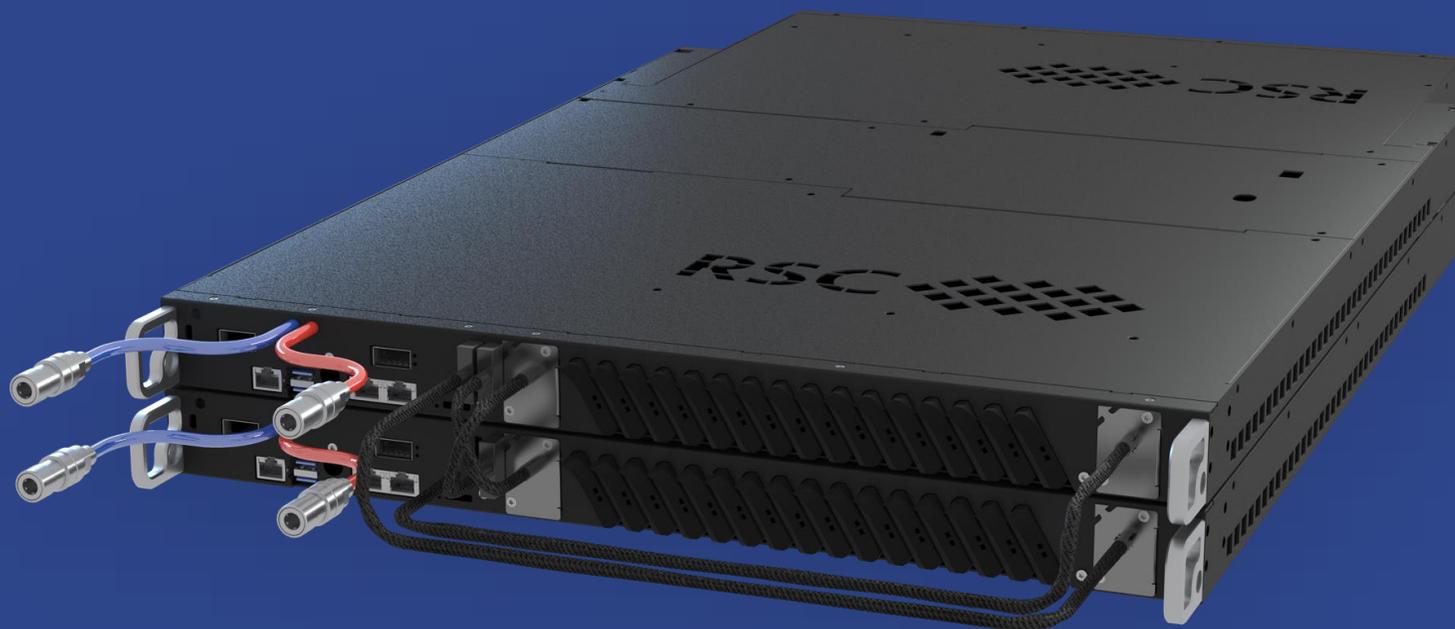
Узел «РСК Экзастрим ИИ»

Параметр	Значение
Поддержка ЦПУ	Intel Xeon Scalable 4-го или 5-го поколения
Оперативная память	DDR5, 32 слота, до 2 ТБ
Поддержка ГПУ	До 8-ми NVidia H100/H200 Pairwise NVLink
Постоянная память	До 8-ми SSD рулеров в форм-факторе EDSFF 1.S, суммарно 128 ТБ
Коммутация	До 4-х портов Infiniband HDR/NDR
Сеть	10 ГБ Ethernet
Система охлаждения	100% жидкостное охлаждение, температура 40-50 С
Блок питания	Разработка РСК, прямое жидкостное охлаждение

RSC Tornado AFS storage with record density



E1.L Intel® Data Center SSDs
в форм-факторе EDSFF



Сверхвысокая емкость – 1 ПБ
в одном сервере (1U)



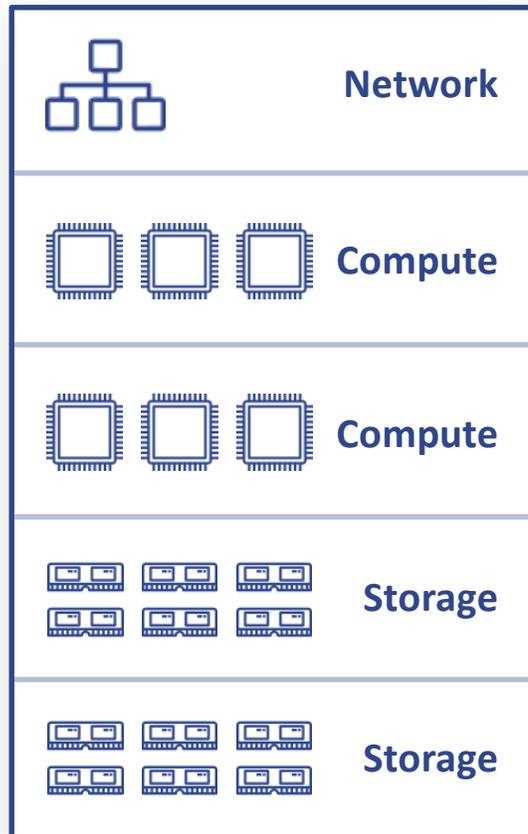
Надежное объединение 2-х серверов
в СХД емкостью 2 ПБ (2U)

Первое решение на 100% жидкостном
охлаждении с высочайшей плотностью
на базе 32x Intel EDSFF SSD, двух
процессоров Intel Xeon Scalable и
памяти Intel Optane DC Persistent
Memory

**100% охлаждение «горячей
водой» позволяет достичь
рекордной энергоэффективности
(PUE < 1,04)**

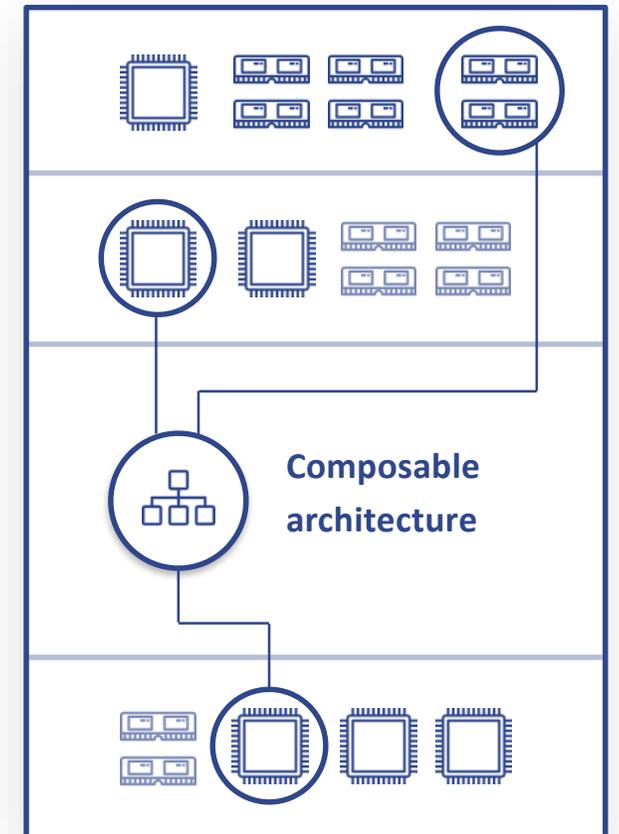
Composable Disaggregated Infrastructure

Rack Scale Architecture



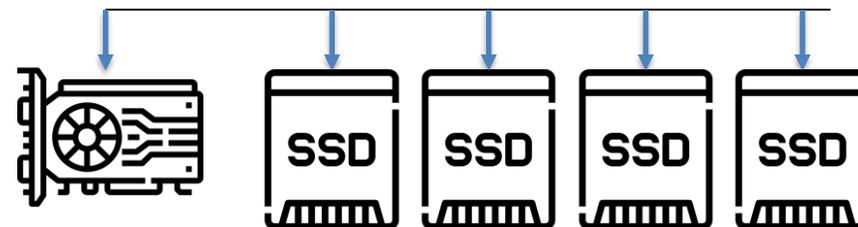
- ⊕ Hyperconvergence
- ⊕ Modern storage and network building blocks
- ⊕ Software orchestration
- ⊕ Storage on-demand
- ⊖ Software virtualization

Composable Disaggregated Infrastructure (CDI)



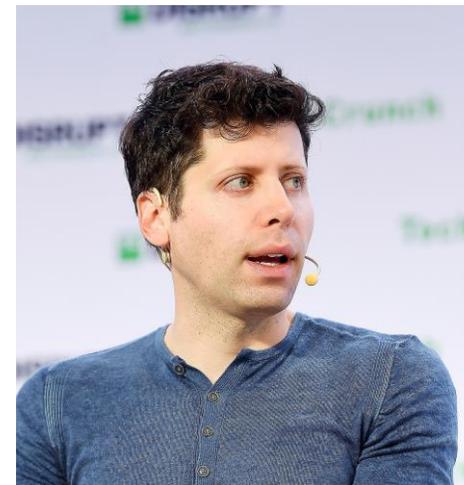
RSC BasIS: GPU Direct and SSD management

- Оптимальное соотношение GPU и SSD под задачу
- GPU Direct – быстрый доступ к данным для приложений на GPU
- NVMe-over-Fabric – управление устройствами хранения
- Патент РФ «Метод построения высокопроизводительных отказоустойчивых систем хранения данных на основе распределенных файловых систем и технологии NVMe over Fabrics»
- Реестр российского ПО (РСК БазИС, РСК Базис СХД)



Сэм Альтман, OpenAI

The rate of new wonders being achieved will be immense. It's hard to even imagine today what we will have discovered by 2035; maybe we will go from solving high-energy physics one year to beginning space colonization the next year;



By TechCrunch - TechCrunch
Disrupt San Francisco 2019 - Day 2,
CC BY 2.0,
<https://commons.wikimedia.org/w/index.php?curid=92008259>

MProt-DPO: Breaking the ExaFLOPS Barrier for Multimodal Protein Design Workflows with Direct Preference Optimization



Gautham Dharuman^{1†}, Kyle Hippe^{1,2†}, Alexander Brace^{1,2†}, Sam Foreman^{1†}, Väinö Hatanpää¹, Varuni K. Sastry¹, Huihuo Zheng¹, Logan Ward¹, Servesh Muralidharan¹, Archit Vasan¹, Bharat Kale¹, Carla M. Mann^{1,2}, Heng Ma¹, Yun-Hsuan Cheng³, Yuliana Zamora³, Shengchao Liu⁵, Murali Emani¹, Tom Gibbs³, Mahidhar Tatineni⁷, Deepak Canchi⁸, Jerome Mitchell⁸, K Maria Garzaran⁸, Michael E. Papka^{1,9}, Ian Foster^{1,2}, Rick Stevens^{1,2}, Anima Anandkumar^{10*}, Venkatram Vishwanath^{1,9*}, Arvind Ramanathan^{1,4}
¹Argonne National Laboratory, ²University of Chicago, ³NVIDIA Inc., ⁴Swiss National Supercomputing Center, ⁵University of California, Berkeley, ⁶University of Wisconsin-Madison, Madison, ⁷San Diego Supercomputer Center, ⁸Intel Corporation, ⁹University of Illinois Chicago, ¹⁰California Institute of Technology
[†]Joint first authors, *Contact authors: venkat@anl.gov, anima@caltech.edu, ramanathana

GenSLMs: Genome-scale language models reveal SARS-CoV-2 evolutionary dynamics

Maxim Zvyagin^{1†}, Alexander Brace^{1,2†}, Kyle Hippe^{1†}, Yuntian Deng^{3,4†}, Bin Zhang⁵, Cindy Orozco Bohorquez⁵, Austin Clyde^{1,2}, Bharat Kale⁶, Danilo Perez-Rivera^{1,7}, Heng Ma¹, Carla M. Mann^{1,2}, Michael Irvin¹, J. Gregory Pauloski², Logan Ward¹, Valerie Hayot-Sasson^{1,2}, Murali Emani¹, Sam Foreman¹, Zhen Xie¹, Diangen Lin^{1,2}, Maulik Shukla^{1,2}, Weili Nie³, Josh Romero³, Christian Dallago^{3,9}, Arash Vahdat³, Chaowei Xiao^{8,3}, Thomas Gibbs³, Ian Foster^{1,2}, James J. Davis^{1,2}, Michael Brettin¹, Rick Stevens^{1,2}, Anima Anandkumar^{3,11*}, Venkatram Vishwanath^{1*}, Arvind Ramanathan^{1*}

¹Argonne National Laboratory, ²University of Chicago, ³NVIDIA Inc., ⁴Harvard University, ⁵Cerebras Inc., ⁶Northern York University, ⁷Arizona State University, ⁸Technical University of Munich, ⁹University of Illinois Chicago, ¹⁰University of California, Berkeley, ¹¹California Institute of Technology
*Contact authors: venkat@anl.gov, anima@caltech.edu, ramanathana@anl.gov

Learning-at-Criticality in Large Language Models for Quantum Field Theory and Beyond

Xiansheng Cai^{1,*}, Sihang Hu^{2,3,*}, Tao Wang^{4,5,†}, Yuan Huang^{6,†}, Pan Zhang^{1,7,§}, Youjin Deng^{2,3,¶} and Kun Chen^{1,**}

¹Institute of Theoretical Physics, Chinese Academy of Sciences, Beijing 100190, China
²Department of Modern Physics, University of Science and Technology of China, Hefei, Anhui 230026, China
³Hefei National Laboratory, University of Science and Technology of China, Hefei 230088, China
⁴Department of Physics, University of Massachusetts, Amherst, MA 01003, USA
⁵Institute of Physics, Chinese Academy of Sciences, Beijing 100190, China
⁶DP Technology, Beijing 100080, China
⁷School of Fundamental Physics and Mathematical Sciences, Hangzhou Institute for Advanced Study, UCAS, Hangzhou 310024, China
(Dated: June 11, 2025)

Fundamental physics often confronts complex symbolic problems with few guiding exemplars or established principles. While artificial intelligence (AI) offers promise, its typical need for vast datasets to learn from hinders its use in these information-scarce frontiers. We introduce learning at criticality (LaC), a reinforcement learning (RL) scheme that tunes Large Language Models (LLMs) to a sharp learning transition, addressing this information scarcity. At this transition, LLMs achieve peak generalization from minimal data, exemplified by 7-digit base-7 addition—a test of nontrivial arithmetic reasoning. To elucidate this peak, we analyze a minimal concept-network model (CoNet) designed to capture the essence of how LLMs might link tokens. Trained on a single exemplar,

Спасибо!



rscgroup.ru

hq@rsc-tech.ru

oleg.gorbachov@rscgroup.ru