




Syntacore™
RISC-V cores and tools

Развитие акселераторов AMD Instinct для суперкомпьютеров и систем искусственного интеллекта



Сведения о докладчике

Тимур Турсунович Палташев — доктор технических наук, профессор и международный эксперт в области микроэлектроники, компьютерной архитектуры и графических процессоров.


- До мая 2025 г. работал старшим менеджером и руководителем проектов в подразделении Radeon Technologies Group и Artificial Intelligence Group в Advanced Micro Devices (AMD)
- Ранее также успешно работал в компании S3 Graphics, в РосАтоме и университетах ИТМО, ВГУ, SDSMT и NPU (SFBU)
- Автор более 70 научных трудов, зарегистрировано 33 патента США в сфере архитектуры микропроцессоров и параллельных вычислительных структур
- В 1991 году стоял у истоков создания GraphiCon — крупнейшей на постсоветском пространстве международной конференции по компьютерной графике и зрению. 36-я конференция в 2026 г.



Гетерогенные процессоры для высокопроизводительных вычислений и задач искусственного интеллекта

AMD Instinct™

MI300A APU, MI300X,
MI350X, MI430X и MI455X
GPUs




Вычислительные блоки GPU в процессоре AMD Instinct™ MI300A




- XCD — Accelerator Complex Die
- 38 CUs per XCD, 228 total AMD CDNA™ 3 architecture

Ядра CPU в процессоре AMD Instinct™ MI300A



- CCD – CPU Complex Die
- 8 “Zen 4” cores per CCD, 24 total
- Leverage CCD from EPYC




Память высокой пропускной способности в процессоре AMD Instinct™ MI300A





- HBM — High Bandwidth Memory
- HBM gen3, 16GB (128 GB total)
- 665 GB/s/stack (5.3 TB/s total)
- 128 total memory channels

Многоканальный кэш для доступа к памяти в процессорах AMD Instinct™ MI300A




- Memory-side Infinity Cache
- 2MB/channel (256 MB total)
- BW amplification (from 5.3 TB/s up to 17 TB/s)

Когерентный интерфейс в процессорах AMD Instinct™ MI300/MI400




- IF — Infinity Fabric
- Fully-coherent fabric (CPU+GPU)
- Provides I/O connectivity
 - Four x16 links to other MI300A (IF)
 - Four x16 links IF or PCIe® gen5
 - Each link at 64 GB/s/dir

Основные компоненты процессора AMD Instinct™ (для MI300A)




Трёхмерная сборка основных компонентов процессоров AMD Instinct™




Трёхмерная конструкция процессоров серии MI350X

- 185 Billion transistors
- 3D Multi-Chiplet (2 chiplet types + HBM3E)
- Heterogenous process technologies
- Proven COWOS-S packaging technology
- Up to 1,400 watts Total Board Power (TBP)




Передовая технология 3D-упаковки гетерогенных модулей и чиплетов




- 8 stacks of HBM
- 6 XCDs
- 3 CCDs
- 4 IODs
- IOD – I/O Die
- 3D hybrid bonding
- 2.5D silicon interposer
 - IOD-IOD links
 - IOD-HBM links

Модульная конструкция с многократным использованием чиплетов

MI300 IOD



CDNA™ 3 XCD



4th-gen EPYC™
“Genoa” CCD



4th-gen EPYC™
“Genoa” IOD



4x IOD


8x XCD

6x XCD


3x CCD

up to 12x CCD


1x IOD



AMD Instinct™
MI300X Accelerator




AMD Instinct™
MI300A APU



4th-gen AMD EPYC™ CPU

Модульный ввод/вывод обеспечивает гибкость масштабирования



OCP open standard UALink in MI430

Детали построения AMD Instinct™ MI300A

Smith, A., Loh, G.H., Schulte, M.J., Ignatowski, M., Naffziger, S., Mantor, M., Kalyanasundharam, M.F., Alla, V., Malaya, N., Greathouse, J.L., Chapman, E., & Swaminathan, R. (2024).

Realizing the AMD Exascale Heterogeneous Processor Vision : Industry Product. 2024 ACM/IEEE 51st Annual International Symposium on Computer Architecture (ISCA), 876-889.

https://www.computermachines.org/joe/publications/pdfs/isca2024_eascale.pdf



Два поколения гетерогенных суперкомпьютеров AMD/HPE

Feature	Frontier (OLCF-5)	Discovery (OLCF-6)
Status / Deployment	Operational since 2022	Planned for 2028
Target Performance	1.35 ExaFLOPS (measured HPL FP64)	~Up to 8.5 ExaFLOPS (estimate based on the spec)
System Architecture	HPE Cray EX	HPE Cray Supercomputing GX5000
CPU Architecture	AMD EPYC "Trento"	AMD EPYC "Venice"
GPU Accelerators	AMD Instinct MI250X	AMD Instinct MI430X
Storage Infrastructure	700 PB Orion Lustre parallel filesystem	Dual-tier: DAOS-based Cray K3000 & Lustre-based E2000
Core Scientific Focus	Exascale modeling and simulation	High-performance simulation & Sovereign AI training



Чудный мир больших языковых моделей LLM: Влияние на GPU

Модели с гораздо большим числом параметров


- Инновации в форматах данных для уменьшения нагрузки на память
- Расширенный набор входных потоков (в частности видео и изображения)
- Требования большего объёма памяти для сохранения параметров

Увеличение длины контекста LLM

- Растущая цепочка рассуждений
- Обработка входных изображений и видео
- Удлиненные текстовые документы для режима генерации выборки с дополнением (RAG)


Увеличение объёма работы с ИИ-агентами

- Явный тренд к методам обучения с подкреплением (RL)
- Генерация синтетических данных создает более адаптивные модели
- Все больше моделей «Смесь Экспертов» переходит на распределенные параллельные вычисления



AMD Instinct MI350X/MI355X: Взгляд изнутри

Блок-диаграмма ускорителя MI355X



Дальнейшее развитие платформы AMD Instinct для суперкомпьютеров

Основные характеристики MI300X, MI350X, MI430X и NVIDIA Rubin

Параметр	AMD Instinct MI300X	AMD Instinct MI350X	AMD Instinct MI430X	NVIDIA Rubin (R200)
Архитектура	CDNA 3	CDNA 4	CDNA 5	Rubin
Память	192 ГБ HBM3	288 ГБ HBM3E	432 ГБ HBM4	288 ГБ HBM4
Пропускная способность	5,3 ТБ/с	8 ТБ/с	23.3 ТБ/с	22 ТБ/с
FP64 FMA real	~81.7 TFLOPs	~72.1 TFLOPs	~ 288 TFLOPs**	33 TFLOPs***
Интерконнект	Infinity Fabric 4	Infinity Fabric 4	Infinity Fabric + UALink	NVLink 6
Домен применения	AI / HPC	AI / LLM	HPC + AI	AI / Агентный

** ~**288 TFLOPs** FP64 Vector — Оценка AMD нативной производительности по инженерным образцам

*** **33 TFLOPs** – Нативная производительность FP64, 200 TFLOPS достигается эмуляцией через Tensor Cores

AMD Instinct™ MI350 Series Air-Cooled Platforms


Leverage Existing Datacenter Infrastructure

- PCIe® Gen 5 attach to CPU Host/NIC Interfaces
- Updated air-flow, inlet temp, and power subsystems

Existing:

- MI300X AC 750W
- MI325X AC 1000W

Universal Base
Board (UBB) 2.0



OCP Accelerator
Module (OAM) x8

1000W Products



4U Options Fit into existing UBB8


Две ветви в архитектуре серии MI400: MI430X и MI455X

В серии MI400 компания AMD перешла к специализации архитектурных решений под задачи как классических суперкомпьютеров, так и кластеров ИИ


- Модель **MI430X** создана для высокоточных научных расчетов (HPC) и обучения суверенного ИИ
- Для вычислительных кластеров искусственного интеллекта выпущена другая версия архитектуры CDNA 5 **MI455X**
- **MI455X** предназначен для ЦОД гиперскэйлеров в составе комплексной архитектуры стоек AMD **Helios**
- Шины Infinity Fabric 5 и OCP UALink, объединяют **72 ускорителя MI455X в единой стойке AMD Helios** с суммарной мощностью до **2,9 Эксафлопс**

Развертывание инфраструктуры мощностью энергопотребления до 6 ГВт для OpenAI и аналогичной для Meta

Другие крупные клиенты по ~2 ГВт: Anthropic, Microsoft Azure, Oracle и Cerebras



Повышение производительности вычислений для задач ИИ



MI455X: Специфика параметров вычислителя для задач ИИ


Пиковая производительность в режиме ИИ	TFLOPS	Со структурированной разреженностью	Декодеры, кодеки и виртуализация	
OSP MXFP4	40265		DECODERS+	4 engines for HEVC/ H.265, AVC/H.264, VP9, or AV1
OSP MXFP6	20133			
OSP MXFP8	20133			
OSP FP8	20133			
MATRIX FP16	5033	10066	JPEG/MJPEG CODEC	40 cores, 10 cores per group
VECTOR FP16	315			
MATRIX FP32	315			
VECTOR FP32	315		VIRTUALIZATION SUPPORT	SR-IOV (Single Root I/O Virtualization)
MATRIX FP64	5*			
VECTOR FP64	5*		MEMORY PARTITIONS	4
MATRIX INT8	5033 TOPS	10066		
MATRIX BF16	5033	10066		

* - 288 TFLOPs in MI430

Для университетов: Акселератор MI350 в формате карты PCIe

GPU Instinct MI350P — первая с 2022 года PCIe-карта серии AMD Instinct

- MI350P предназначен для совместимых серверов с поддержкой двухслотовых PCIe-ускорителей и соответствующими требованиями к питанию и воздушному охлаждению
- По числу вычислительных блоков, объему HBM и пропускной способности памяти MI350P соответствует половине конфигурации MI350X
 - XCD: TSMC N3 — такой же, как у MI350X, при этом у MI350X восемь XCD-вычислительных акселераторов, а у MI350P — только четыре
 - IOD: TSMC N6 — один кристалл в MI350P вместо двух у MI350X.
- На картах MI350P нет прямых GPU-to-GPU каналов Infinity Fabric, как это было на картах MI210
- Обмен идет только через PCIe 5.0 x16, что ограничивает скорость параллельно работающих GPU
- *** Вероятно это последствия комбинации экспортного контроля и желания продавать дорогие готовые сервера и стойки



Программная экосистема HIP/ ROCm™ / TheRock

Фреймворки и приложения

PyTorch, TensorFlow, Kokkos, RAJA

Библиотеки ИИ и обработки данных

MIOpen, MigraphX, MIVisionX, RPP

Математические библиотеки и параллельные примитивы

rocBLAS / hipBLAS, rocSPARSE / hipSPARSE,
rocFFT / hipFFT, rocRAND / hipRAND,
rocSOLVER / hipSOLVER, rocPRIM, rocThrust,
rocWMMA

Передача данных между ГП

RCCL, rocSHMEM

Модели программирования и API



HIP, OpenMP, OpenCL

Компиляторы и среды выполнения

LLVM/Clang, hipcc, HIP Runtime, ROCr

Инструменты разработки и управления

ROCgdb
ROCprofiler-SDK
rocprofv3
AMD SMI
rocminfo



Общий подход к использованию AMD Instinct™ в среде ROCm

AMD предлагает набор программ, упрощающих переход с Nvidia GPU

1. УПРОЩЕНИЕ ПРОГРАММИРУЕМОСТИ И ПЕРЕНОСИМОСТИ КОДА

- Поддержка заказчиков в режиме Drop-in для облегчения миграции ведущих AI фреймворков и моделей высокопроизводительных вычислений
- Облегчение переносимости, упрощение программируемости и удобства пользования для ускорения получения конечных результатов
- Богатый набор высокопроизводительных и эквивалентных библиотек, а также программных инструментов для повышения производительности

2. РАСТУЩАЯ ЭКОСИСТЕМА ОТКРЫТОГО КОДА ДЛЯ HPC & AI


- Растущий репозиторий портированных и оптимизированных приложений через углубленное партнерство с ведущими клиентами в доменах HPC & AI
- Стек открытого кода ROCm и модель кросс-программирования CUDA $\leftrightarrow$ HIP
- Активные инвестиции и участие в инициативах по разработке кросс-платформенного открытого кода (OpenXLA, Triton, MLIR)
- Сотрудничество с OpenAI, Meta и Microsoft Azure в разработке экосистемы для задач искусственного интеллекта

Стек программного обеспечения ROCm™ 7.14.0

MIT/BSD License

Apache License

GPL License



ROCm Core SDK 7.14.0 и TheRock

ROCm Core SDK 7.14.0 является переходным этапом от ROCm к **TheRock**, к новой системе генерации и релиза, которая будет иметь модульную архитектуру для улучшения гибкости, поддержки системы и приближения к различным нуждам сообщества разработчиков:

- **Leaner core:** Ядро SDK, сфокусированное на важнейших компонентах среды исполнения и разработки приложений
- **Use case-specific expansions:** Оптимизированные специфические SDKs для задач ИИ, работы с большими данными и высокопроизводительных научных вычислений
- **Modular installation:** Устанавливаются только компоненты, необходимые для конкретного рабочего процесса у пользователя

Поддержка инференса и фреймворков в задачах ИИ:

- PyTorch 2.12.0, JAX 0.10.0, vLLM 0.23.0, SGLang 0.5.13, TensorFlow 2.21

Расширена поддержка графических ядер на следующие продукты Ryzen:

- AMD Ryzen AI MAX+ PRO 495 (gfx1151), AI MAX PRO 490 (gfx1151), AI MAX PRO 485 (gfx1151),
- AMD Ryzen AI 5 435 (gfx1153), AI 5 430 (gfx1153), AI 5 PRO 435 (gfx1153), AI 7 445 (gfx1153)

TheRock (The HIP Environment and ROCm Kit)

это облегченная платформа открытого кода для HIP and ROCm для упрощенного доступа к новейшим возможностям ROCm

Второе издание учебника HIP/ROCm в серии «Суперкомпьютерное образование»


Ифань Сун, Сабила аль-Джаннат, Тринаян Баруа,
Дэвид Каэли

ВЫСОКОПРОИЗВОДИТЕЛЬНЫЕ ВЫЧИСЛЕНИЯ С ПОМОЩЬЮ HIP

Учебное пособие

Второе издание на русском языке

На основе второго издания на английском языке,
опубликованного в США; актуализировано и
дополнено



Второе издание на
английском языке —
Amazon

Генеральный спонсор проекта ООО «ЭСИК»



Итоги целевого сбора на второе издание

- В связи с прекращением ранее предусмотренного финансирования проводится целевой сбор средств для завершения проекта
- **Целевая сумма сбора для проекта — 800 тыс. рублей**
- Средства для финальной издательской подготовки, выпуска электронной версии и печати базового тиража, а также на оплаты уже выполненных переводческих и редакционных работ
- Механизм финансирования — целевой сбор пожертвований
- Оператор сбора — Фонд развития прикладной математики и информационных технологий имени академика А. Н. Тихонова
- **Проект соответствует ключевым направлениям деятельности Фонда:** содействие исследованиям в области вычислительной математики, математического моделирования, компьютерных наук, искусственного интеллекта и в других областях математики и информатики, а также изучение и обобщение опыта, научной и практической деятельности российских, зарубежных и международных организаций
- **Поддержите выпуск систематического учебного пособия и справочника по HIP/ROCm.** Страница целевого сбора на портале Фонда имени А. Н. Тихонова:
<https://tikhonovfoundation.ru/projects/19>

**Страница
целевого сбора**





SyntacoreTM
RISC-V cores and tools

**Спасибо
за внимание!**

Разница между поколениями AMD Instinct™ MI200 и MI300

		AMD Instinct MI250X (Up to)	AMD Instinct MI300A (Up to)	AMD Instinct MI300X (Up to)
Hardware Specs	Memory Capacity	128 GB HBM2e	128 GB HBM3	192 GB HBM3
	Memory Bandwidth (Peak Theoretical)	~3.2 TB/s	~5.3 TB/s	~5.3 TB/s
	Scale-Out (Back-end) Network Bandwidth	200 Gb/s Ethernet/IB	400 Gb/s Ethernet/IB	400 Gb/s Ethernet/IB
	Max TDP/TBP	560 W	760 W	760 W
	Heterogeneous Integration	2D IF, 2.5D EFB, 3D μbump HBM	2.5D passive silicon interposer, 3D HB active interposer and multiple chiplets, 3D μbump HBM	
HPC Peak Perf. (Peak)	FP64 Vector (TFLOPS)	47.9	61.3	81.7
	FP32 Vector (TFLOPS)	47.9	122.6	163.4
	FP64 Matrix (TFLOPS)	95.7	122.6	163.4
	FP32 Matrix (TFLOPS)	95.7	122.6	163.4
AI Peak Perf. (Peak)	TF32* [TF32 Sparsity] (Matrix)	Not Supported	490.3 [980.6]	653.7 [1307.4]
	FP16 [FP16 Sparsity] (TFLOPS)	383.0 [Not Supported]	980.6 [1961.2]	1307.4 [2614.9]
	BFLOAT16 [BF16 Sparsity] (TFLOPS)	383.0 [Not Supported]	980.6 [1961.2]	1307.4 [2614.9]
	FP8* [FP8 Sparsity] (TFLOPS)	Not Supported	1961.2 [3922.3]	2614.9 [5229.8]
	INT8 [INT8 Sparsity] (TOPS)	383.0 [Not Supported]	1961.2 [3922.3]	2614.9 [5229.8]