

5-й Московский суперкомпьютерный форум (МСКФ 2014)

**Инновационные суперкомпьютерные
технологии и проблемы создания
отечественной перспективной
элементной базы**

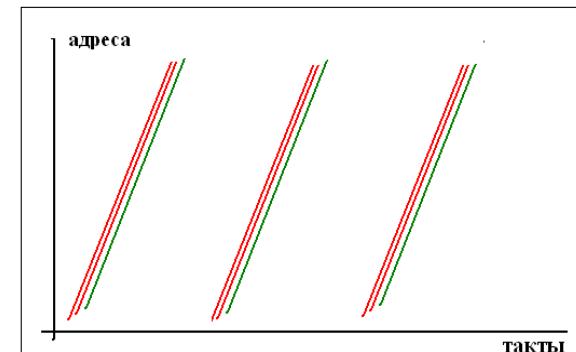
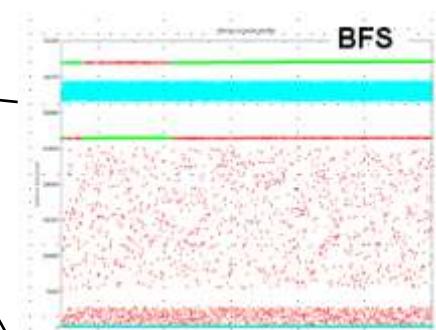
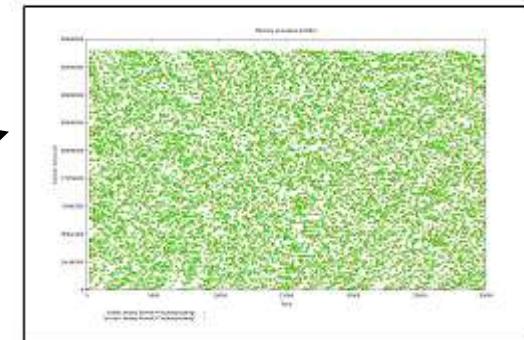
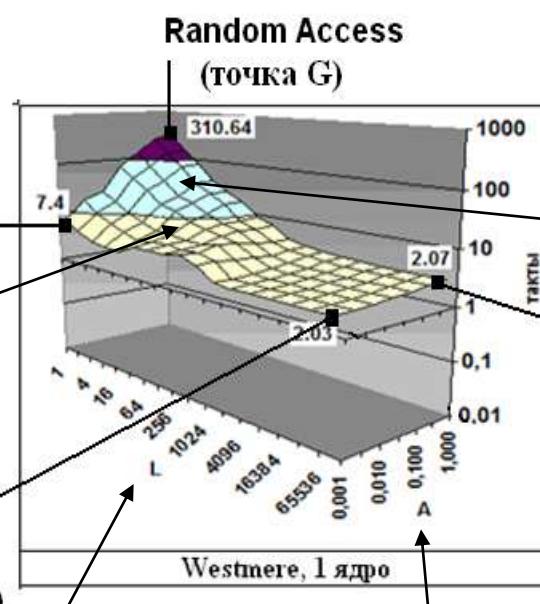
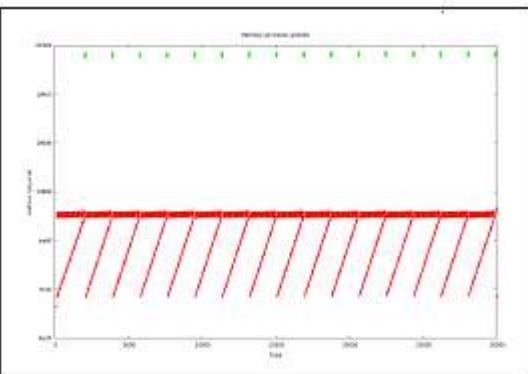
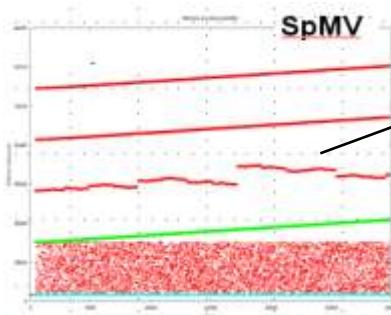
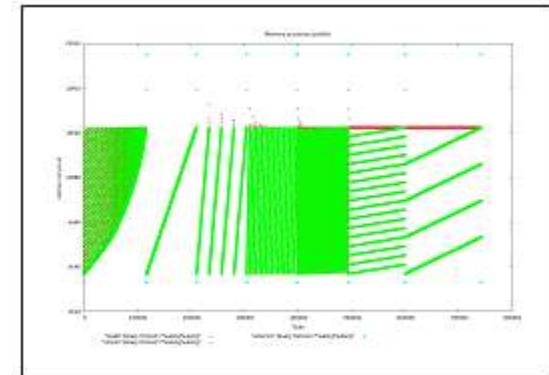
**Л.К.Эйсымонт, В.С.Горбунов
(21 октября 2014 года)**

Общая картина в области СКТ

(на примере инновационных проектов США)

- Внедрение результатов программы DARPA HPCS (2002-2010), коммерческие образцы и военные (заказные) суперЭВМ (2013-2017)
- Выполнение программы DARPA UHPC (2010-2020) и программ DoE по экзасштабным технологиям и суперЭВМ экза-уровня (2012-2023)
- Выполнение программы DARPA STARNet (с 2013 года, на 10-15 лет) по оптимизации использования КМОП-технологий и разработки технологий пост-Муровской эры, зетта- и йотта-уровень производительности

Главная проблема “стены памяти” проекта DARPA HPCS и аналогичных проектов Японии и Китая



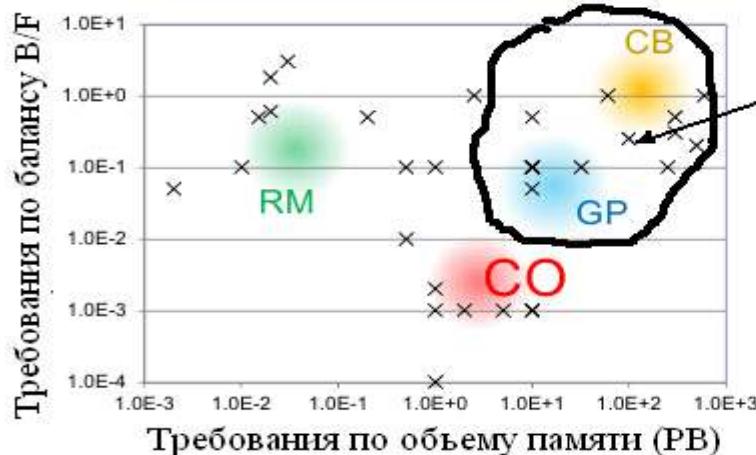
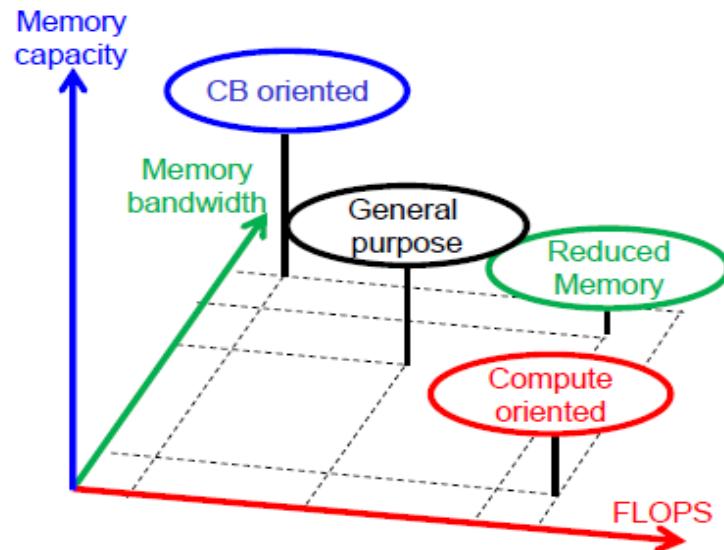
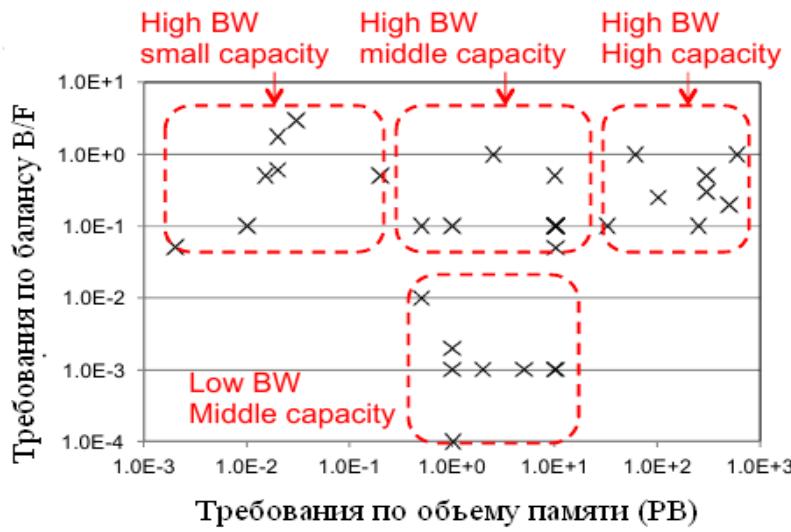
Пространственная локализация

Временная локализация

Рейтинг на вычислительных задачах - тест HP Linpack в сравнении с HPCG

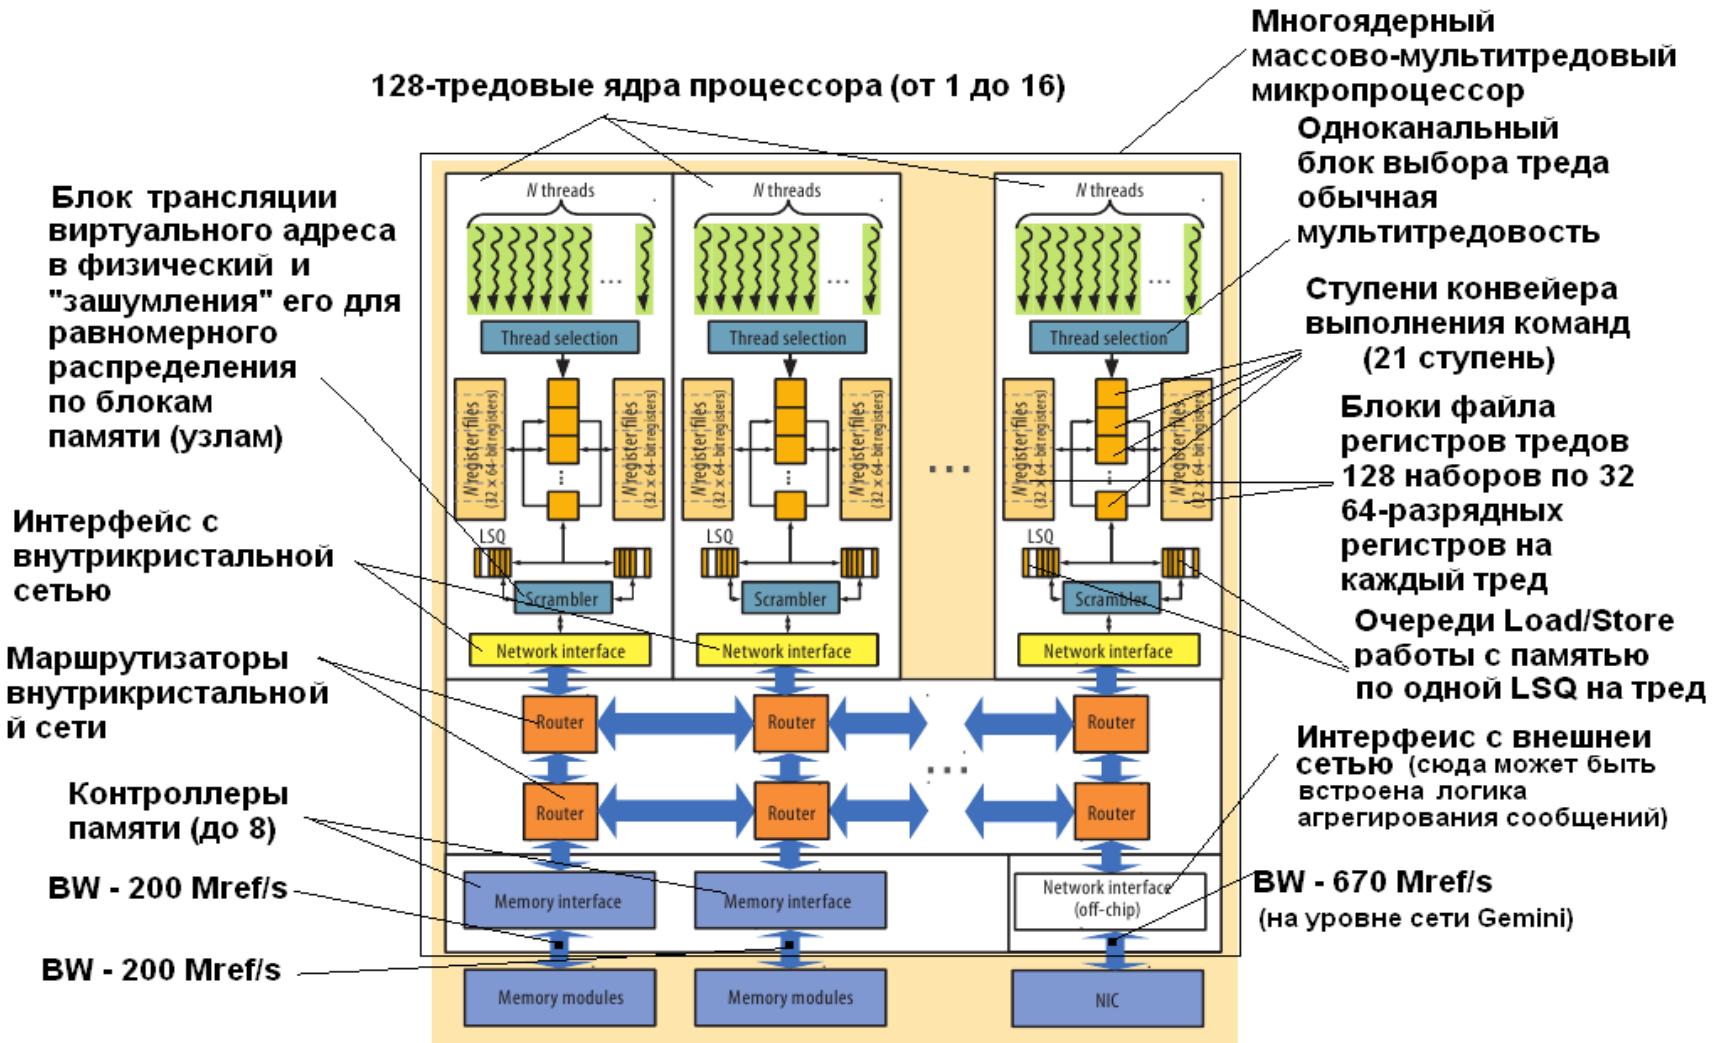
Site	Computer	Cores	HPL Rmax (Pflops)	HPL Rank	HPCG (Pflops)	HPCG/HPL
NSCC / Guangzhou	Tianhe-2 NUDT, Xeon 12C 2.2GHz + Intel Xeon Phi 57C + Custom	3,120,000	33.9	1	.580	1.7%
RIKEN Advanced Inst for Comp Sci	K computer Fujitsu SPARC64 VIIIfx 8C + Custom	705,024	10.5	4	.427	4.1%
DOE/OS Oak Ridge Nat Lab	Titan, Cray XK7 AMD 16C + Nvidia Kepler GPU 14C + Custom	560,640	17.6	2	.322	1.8%
DOE/OS Argonne Nat Lab	Mira BlueGene/Q, Power BQC 16C 1.60GHz + Custom	786,432	8.59	5	.101*	1.2%
Swiss CSCS	Piz Daint, Cray XC30, Xeon 8C + Nvidia Kepler 14C + Custom	115,984	6.27	6	.099	1.6%
Leibniz Rechenzentrum	SuperMUC, Intel 8C + IB	147,456	2.90	12	.0833	2.9%
CEA/TGCC-GENCI	Curie fine nodes Bullx B510 Intel Xeon 8C 2.7 GHz + IB	79,504	1.36	26	.0491	3.6%
Exploration and Production Eni S.p.A.	HPC2, Intel Xeon 10C 2.8 GHz + Nvidia Kepler 14C + IB	62,640	3.00	11	.0489	1.6%
DOE/OS L Berkeley Nat Lab	Edison Cray XC30, Intel Xeon 12C 2.4GHz + Custom	132,840	1.65	18	.0439 *	2.7%
Texas Advanced Computing Center	Stampede, Dell Intel (8c) + Intel Xeon Phi (61c) + IB	78,848	.881*	7	.0161	1.8%
Meteo France	Beaufix Bullx B710 Intel Xeon 12C 2.7 GHz + IB	24,192	.469 (.467*)	79	.0110	2.4%
Meteo France	Prolix Bullx B710 Intel Xeon 2.7 GHz 12C + IB	23,760	.464 (.415*)	80	.00998	2.4%
U of Toulouse	CALMIP Bullx DLC Intel Xeon 10C 2.8 GHz + IB	12,240	.255	184	.00725	2.8%
Cambridge U	Wilkes, Intel Xeon 6C 2.6 GHz + Nvidia Kepler 14C + IB	3584	.240	201	.00385	1.6%
TiTech	TUSBAME-KFC Intel Xeon 6C 2.1 GHz + IB	2720	.150	436	.00370	2.5%

Классификация суперкомпьютеров (далее будем использовать)



Наиболее актуальна
проблема "стены памяти"

Предполагаемый базовый микропроцессор заказных суперкомпьютеров СВ-класса - развитие Threadstorm (Cray XMT)



Петафлопс и траспетафлопс

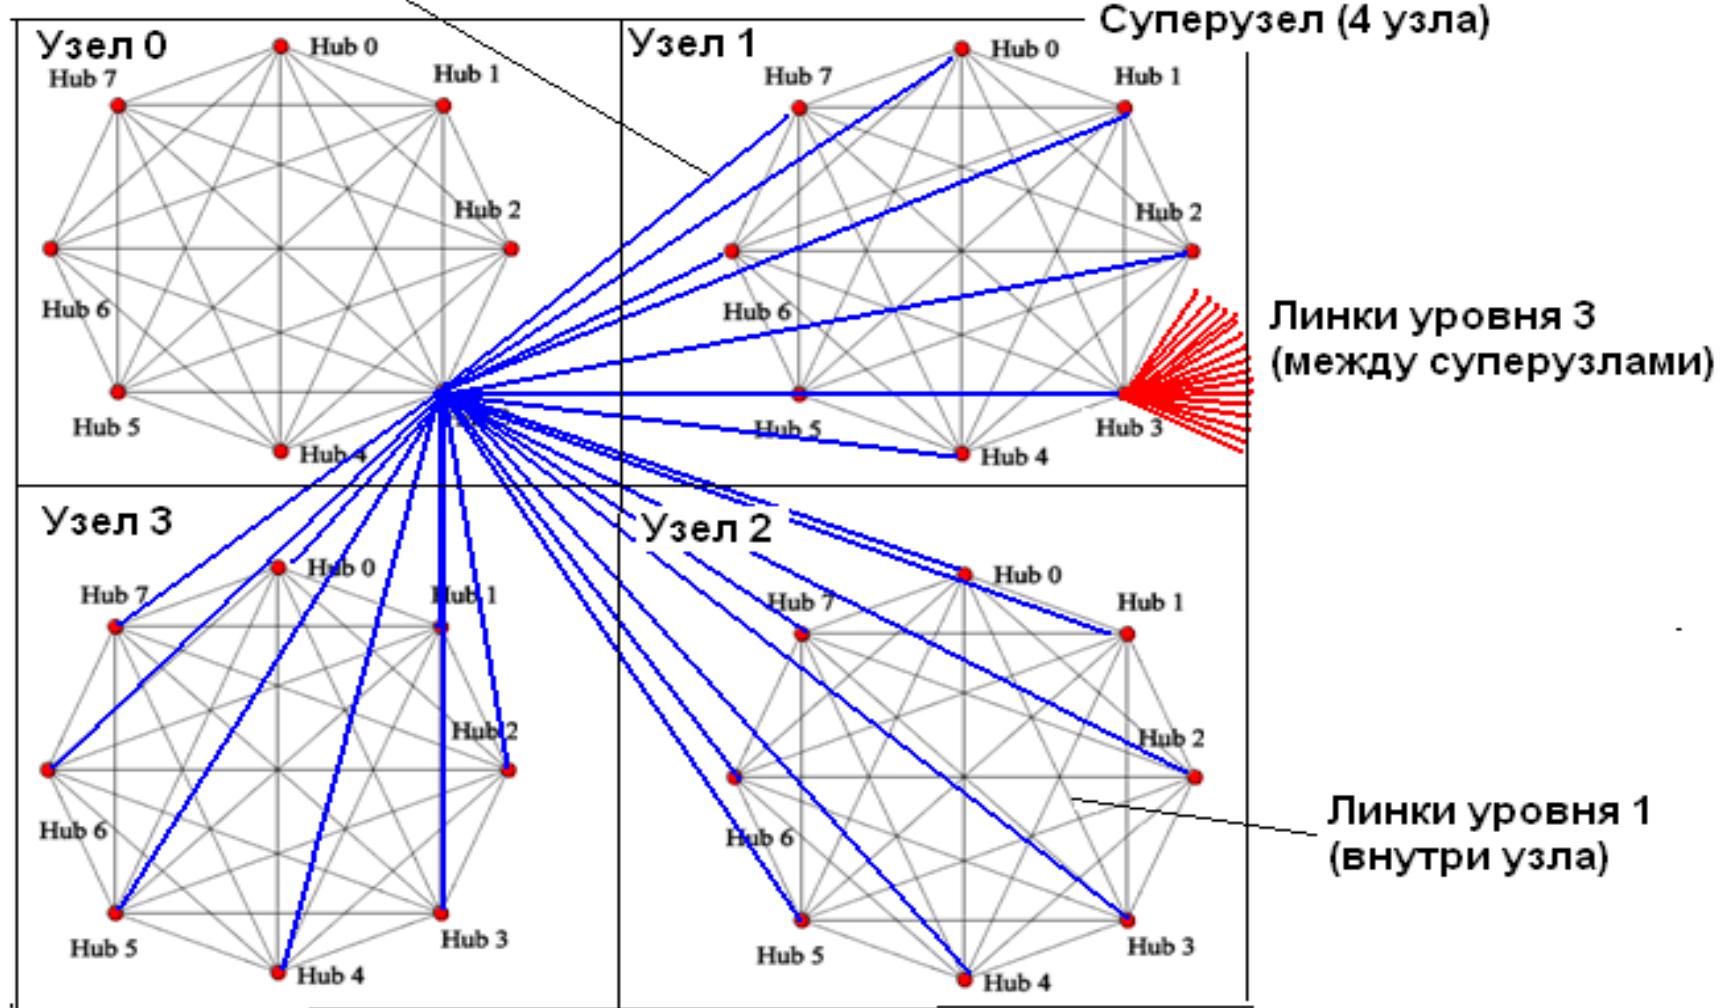
(США, Япония, Китай – инновационные СКТ
Россия – эволюционные СКТ)

Узел и макроузел IBM Power 775

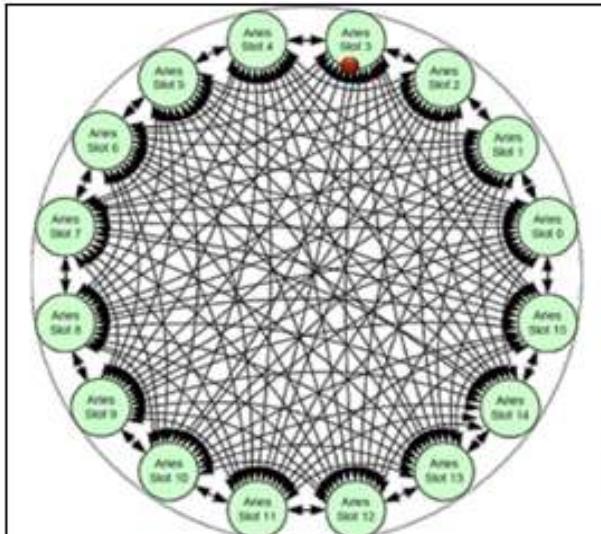
Внутренняя сеть макроузла	
	4-х процессорный узел (4 Power7 + HUB)

Многоуровневая сеть PERCS суперкомпьютера Power 775

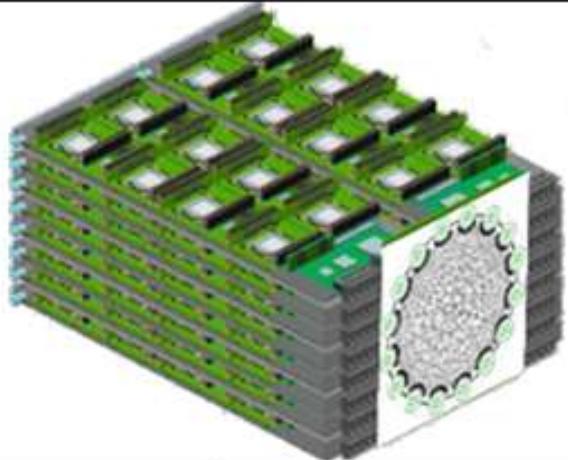
Линки уровня 2
(внутри суперузла)



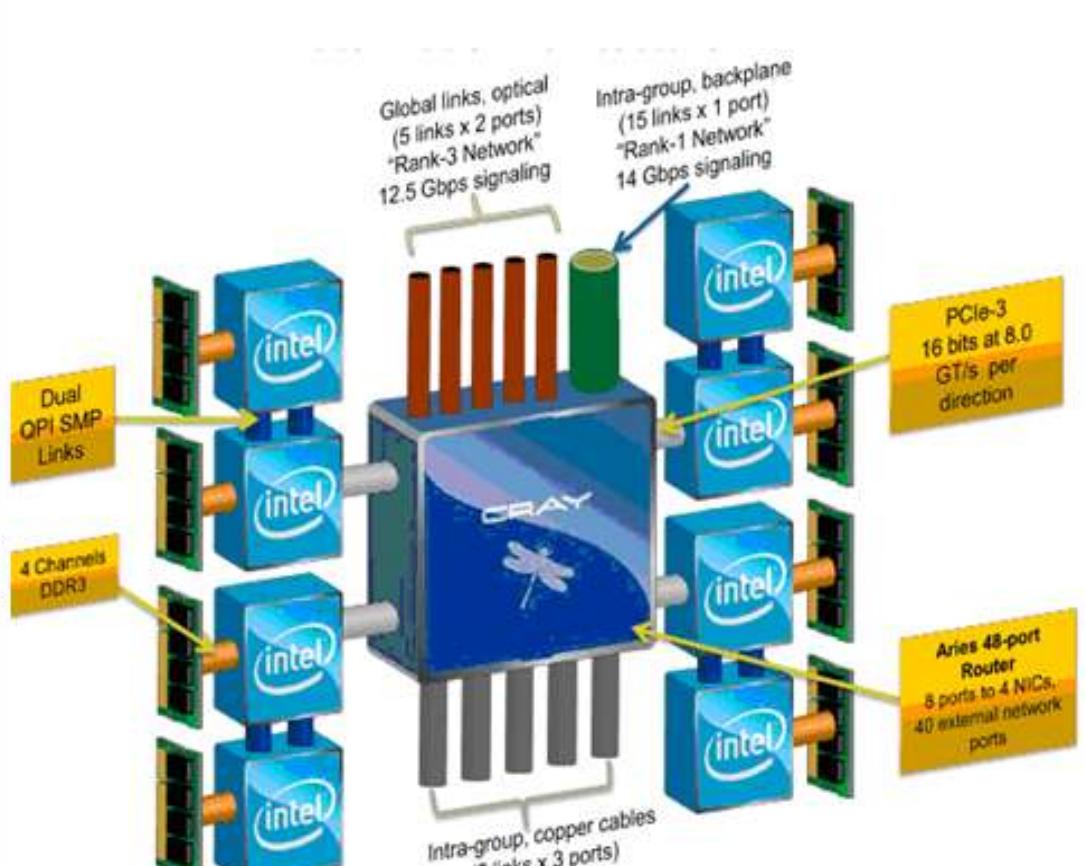
Узел и макроузел Cray XC30



Внутренняя сеть макроузла

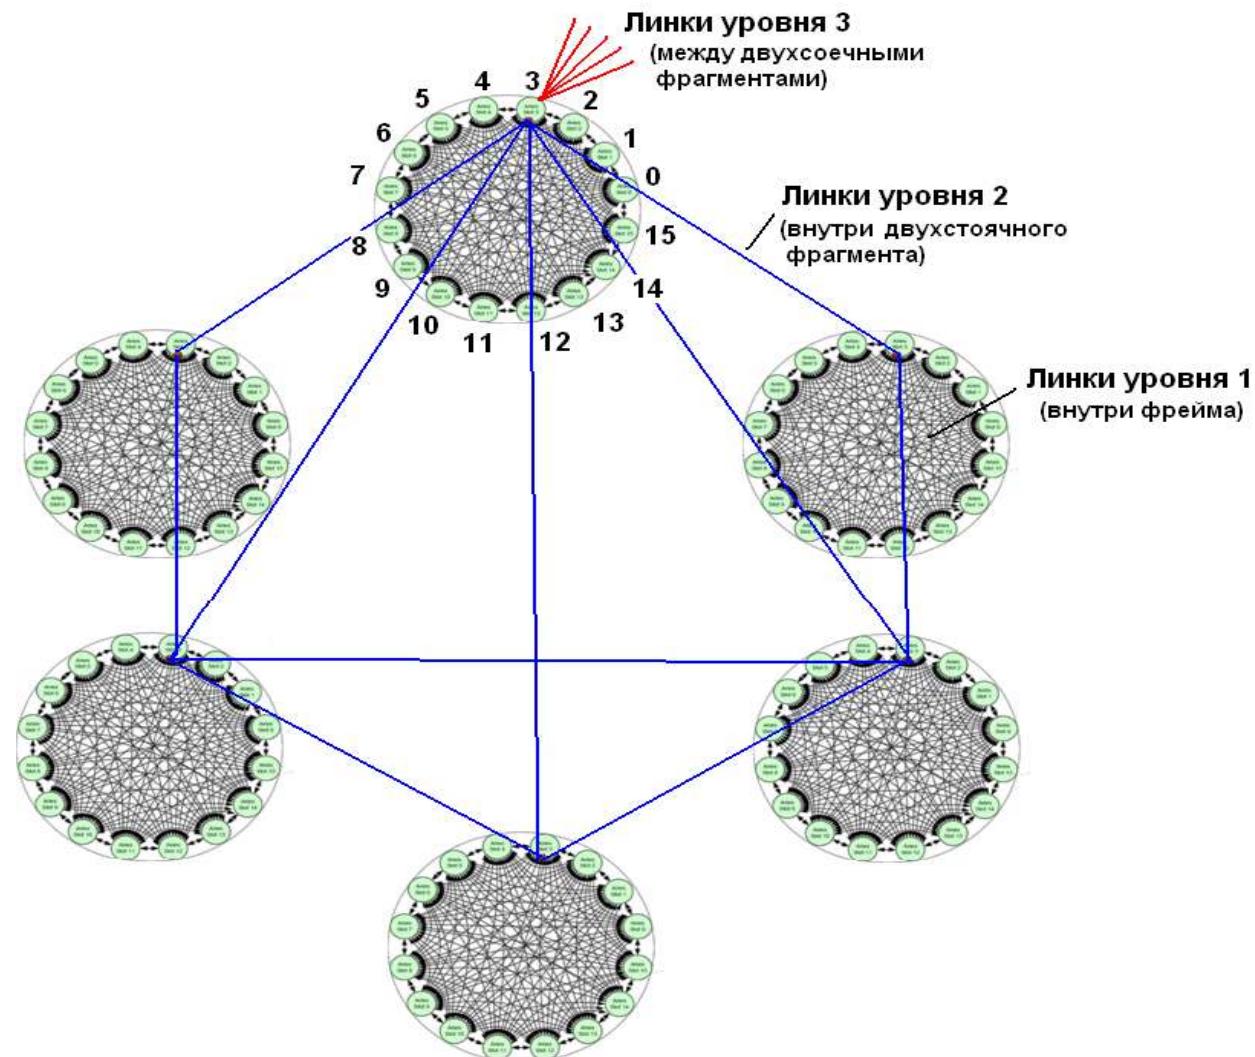


Внешний вид макроузла



8-ми процессорный узел (8 Intel + YARC)

Многоуровневая сеть суперкомпьютера Cray XC30



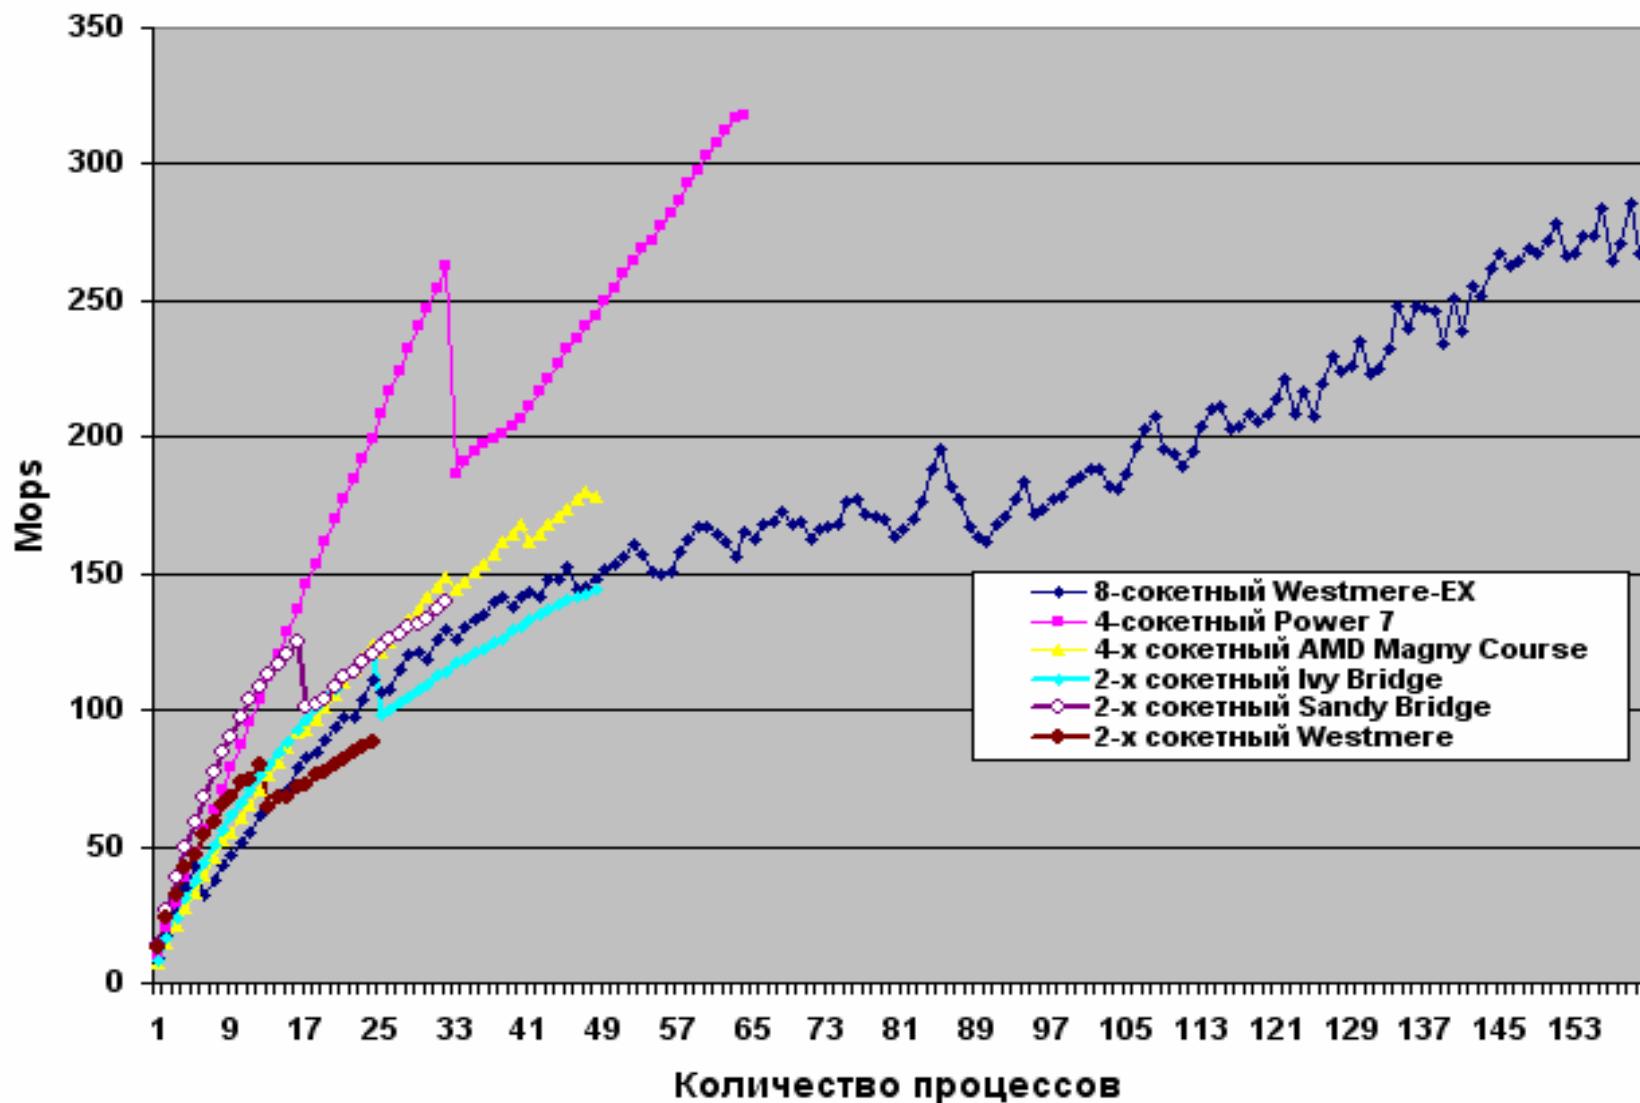
Реальная история и перспектива суперкомпьютеров NERSC (LBNL)

System attributes	NERSC-6	NERSC-7	NERSC-8 (<i>proposed</i>)	NERSC-9 (<i>Proposed</i>)
	Hopper	Edison	Cori 2015-2016	? 2019-2020
System peak	1.3 PF	2.6PF	20-40PF	200-300 PF
Power	2.9 MW (Peak) 2.2MW (Typical)	2.3 MW (Peak) 1.6 MW (Typical)	<5 MW (Peak)	< 15 MW (peak)
System memory	0.21 PB	0.35 PB	1-2 PB	~10 PB (128 GB on package, 512-1024 GB DRAM)
Node performance	202GF	460 GF	2-3.5TF	~10 TF
Node memory BW	50 GB/s	90 GB/s	100-500 GB/s	~200 GB/s ? 2-4 TB/s on package
Node concurrency	24 AMD Magnycours cores	24 Intel Ivy Bridge Cores	up to 300 Knight Landing Haswell	Up to 2048
System size (nodes)	6,384 nodes	5,576 nodes	8,000-12,000 nodes	O(10,000)
MPI Node Interconnect BW	~3 GB/s	~9GB/s	~9 GB/s	Up to 50 GB/s

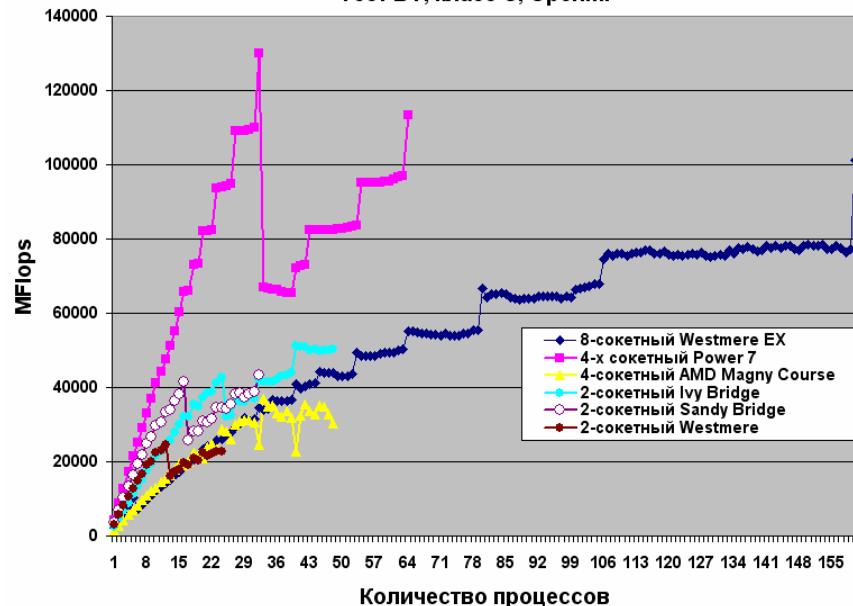
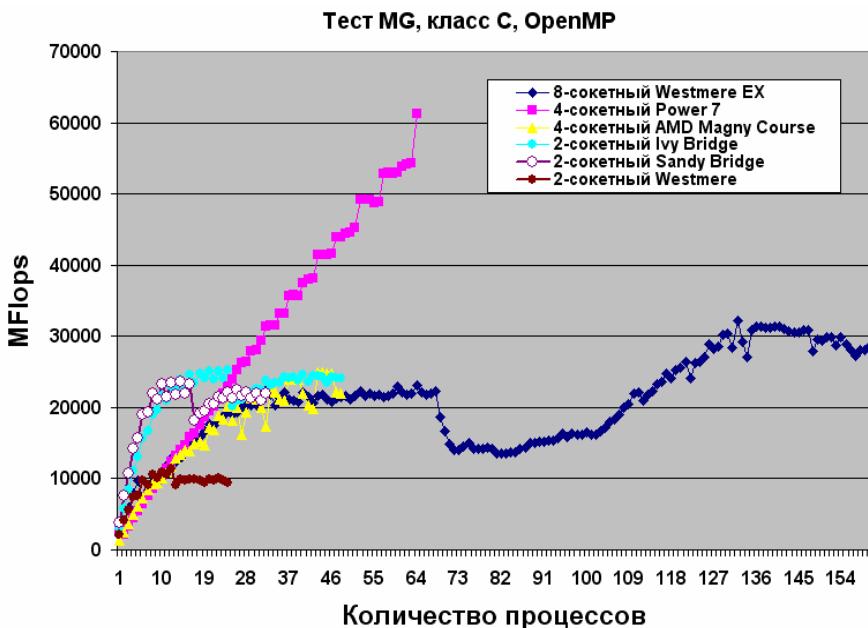
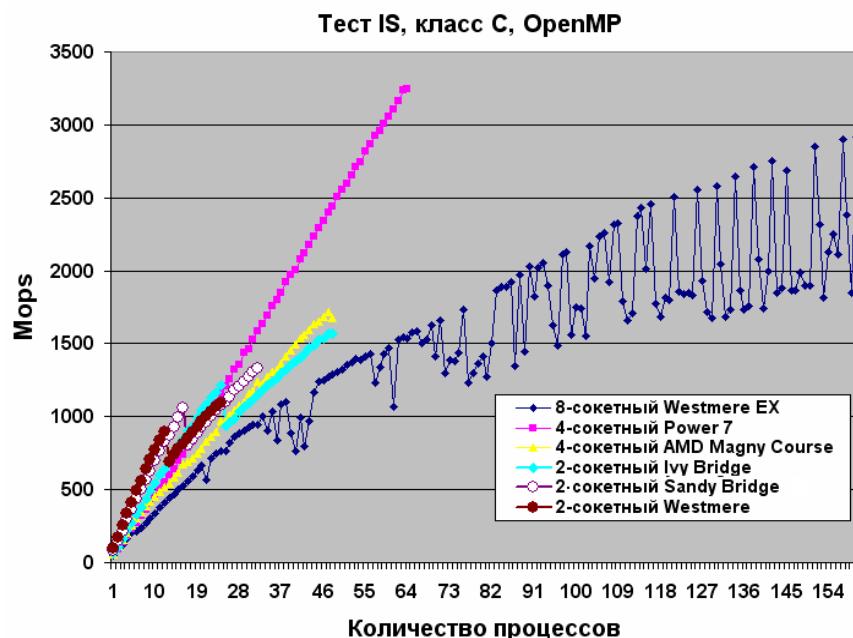
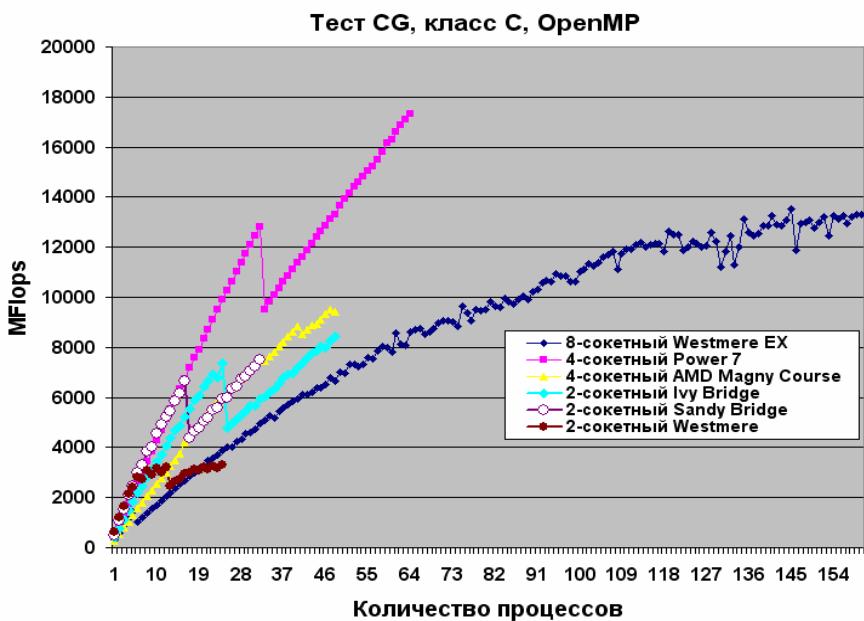
IBM p775: один QCM (4-х процессорный узел)

IBM Power 775 - тест UA (класс C)

Тест UA, класс C, OpenMP

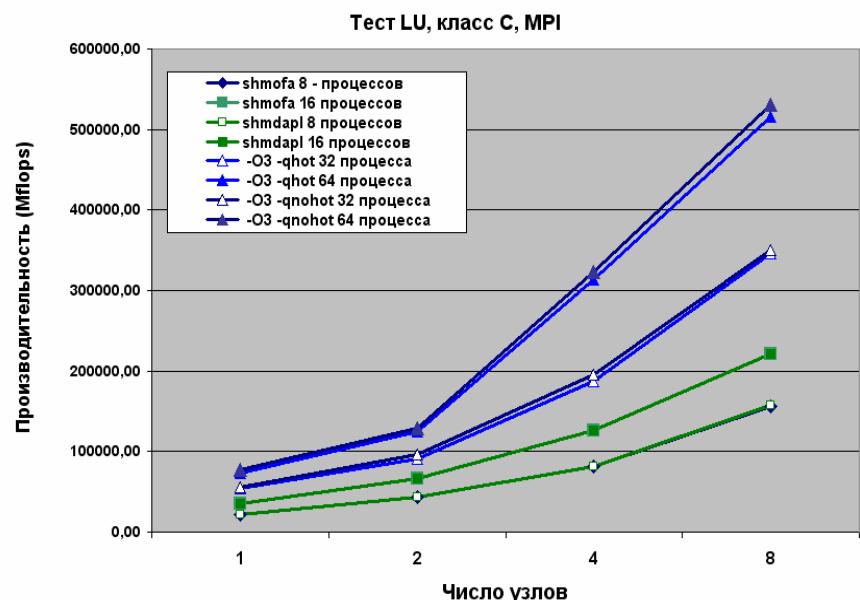
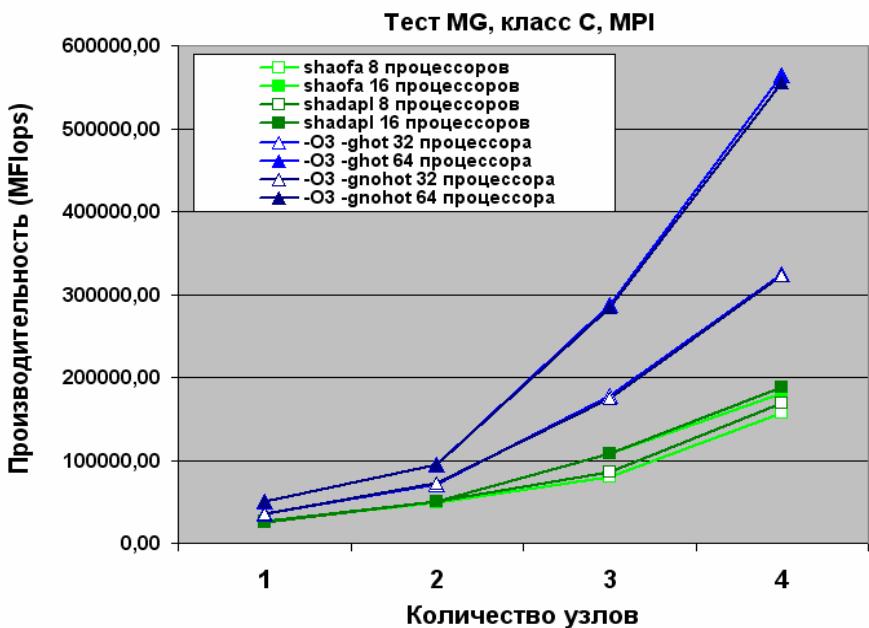
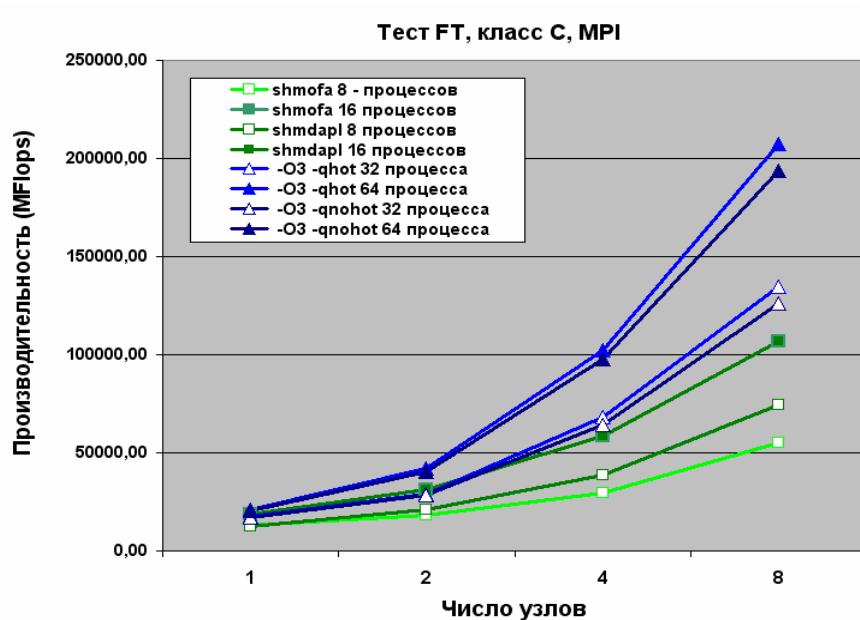
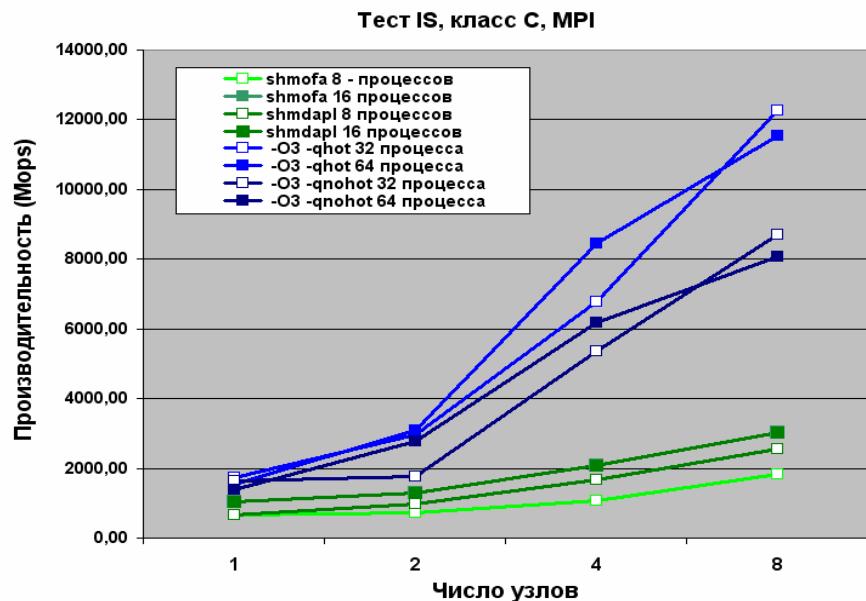


IBM Power 775 - тесты CG, IS, MG, BT

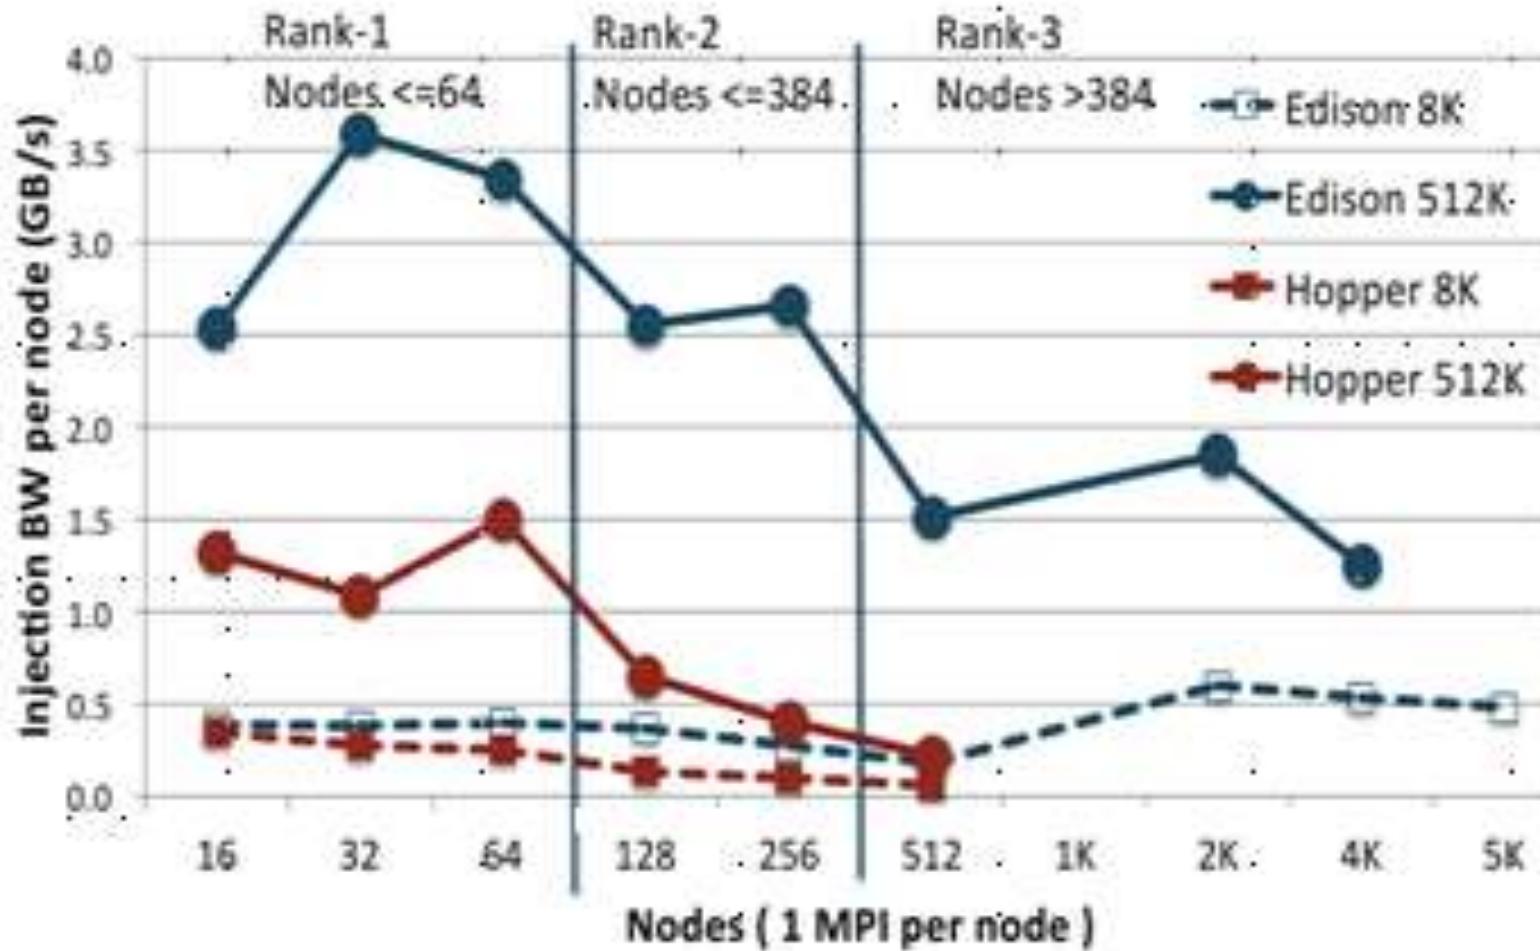


**IBM p775: много QCM одной
серверной платы
(на ней до 8 QCM, это
макроузел первого уровня)**

IBM Power 775 - тесты IS, FT, MG, LU

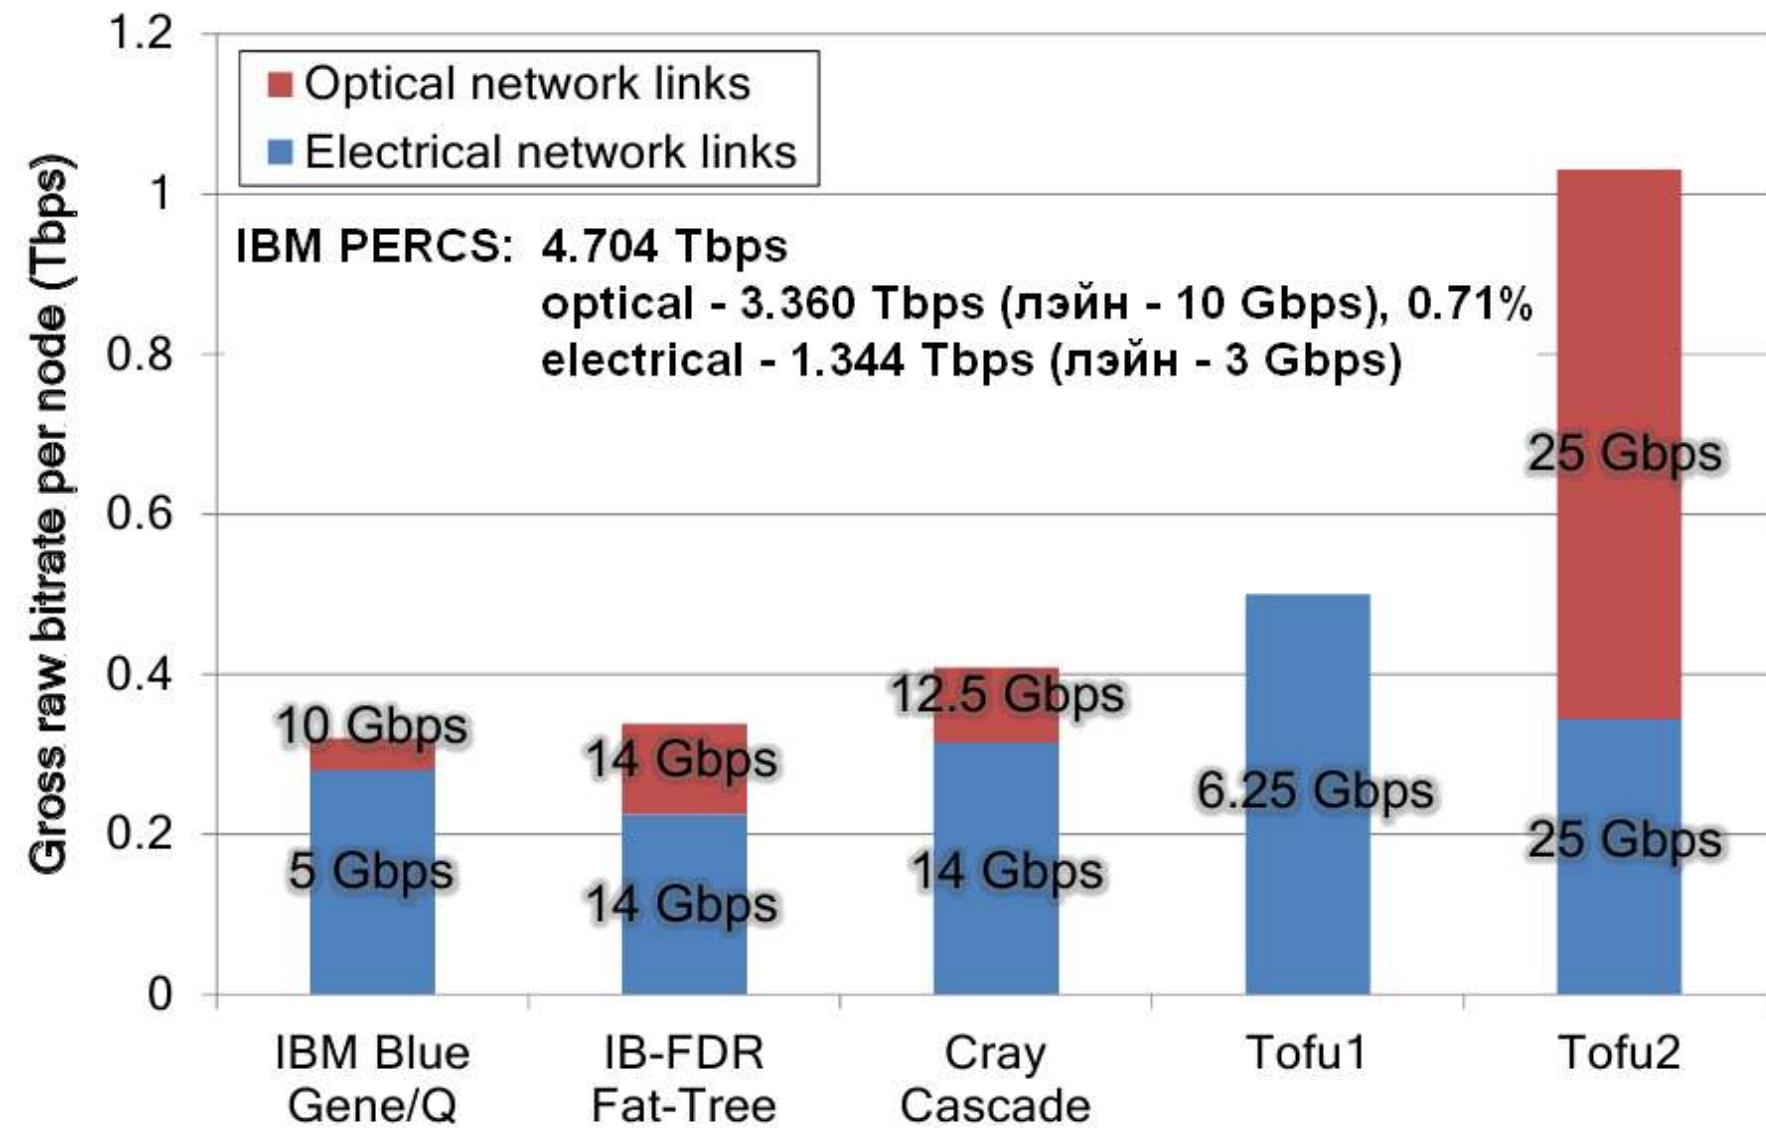


Cray XC30 (Edison, сеть Aries) эффективность Alltoall в сравнении с Cray XE6 (Hopper, сеть Gemini, 3D-тор)

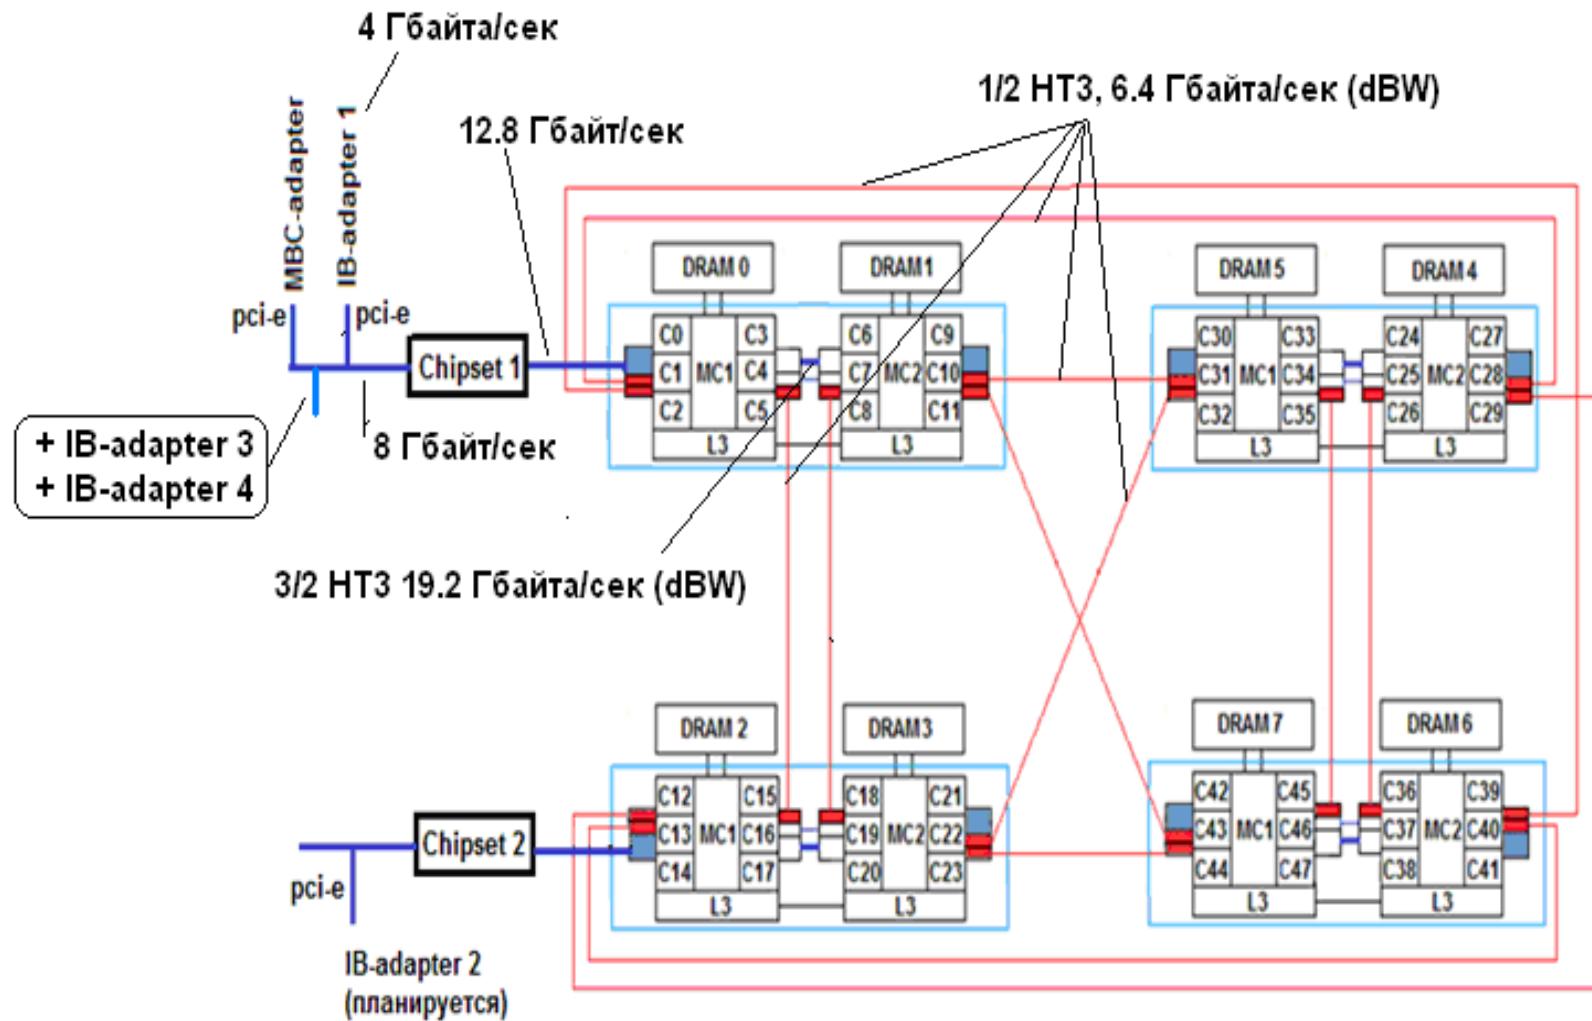


“Петафлопсные возможности” эволюционных СКТ

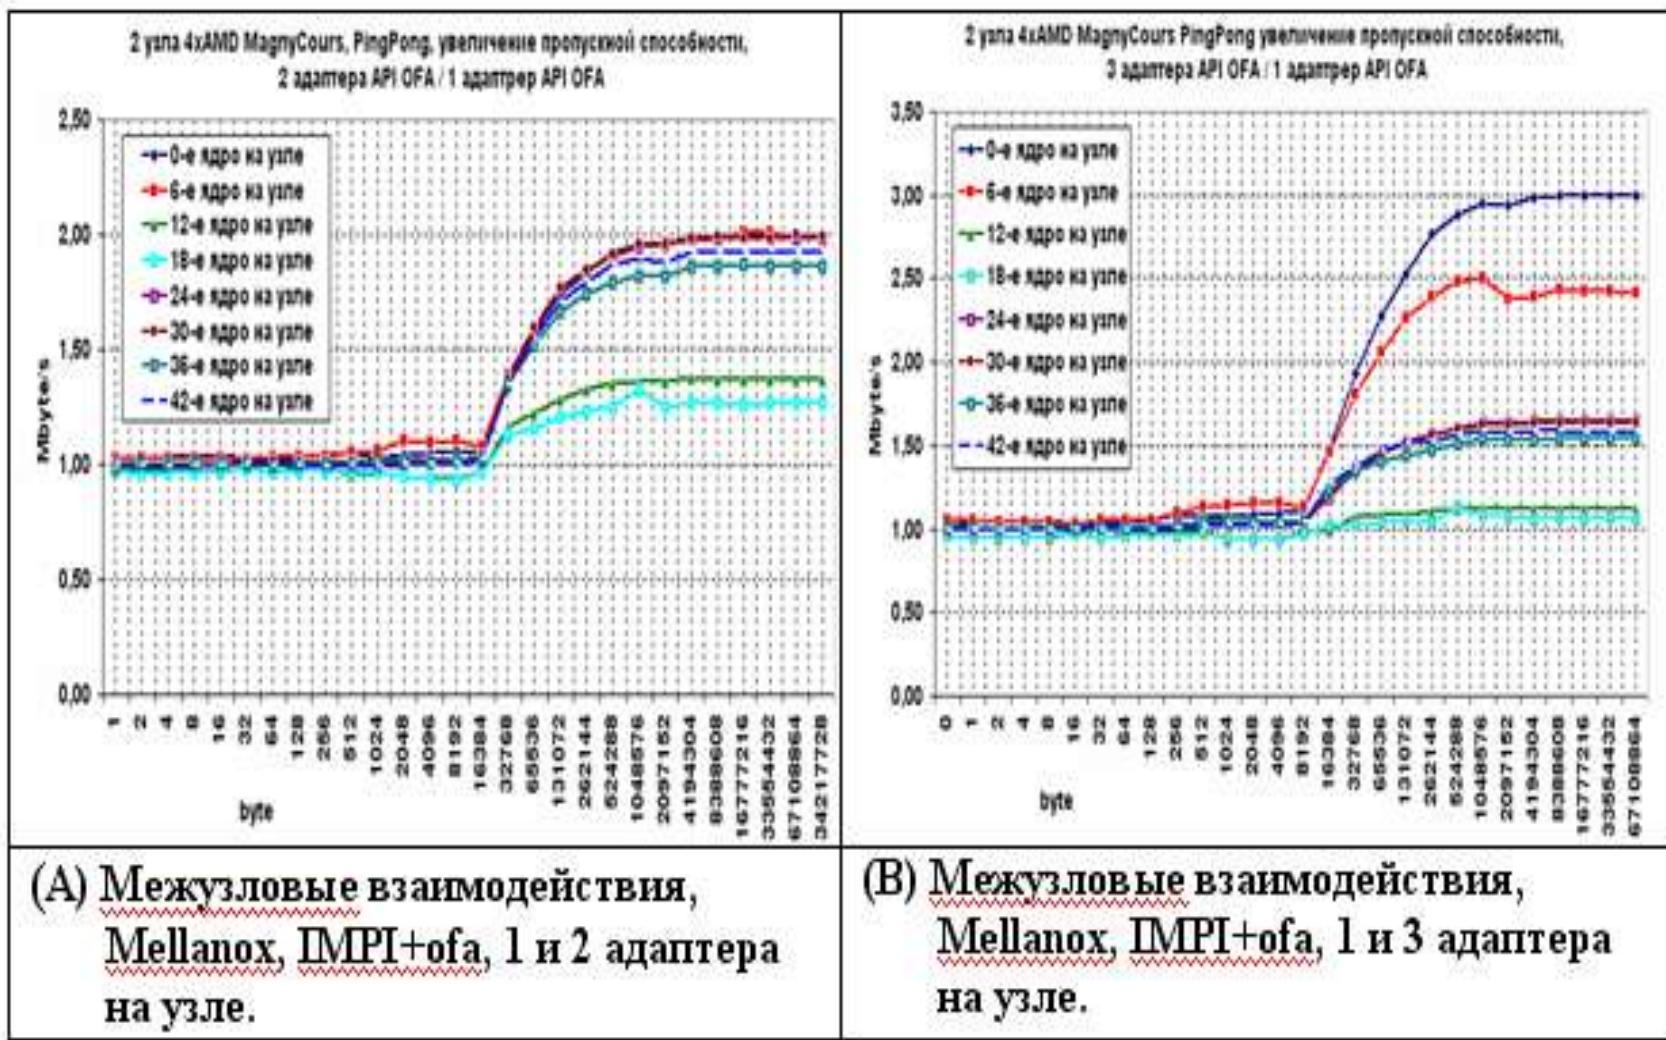
Сравнение пропускных способностей лэйнов, маршрутизаторов



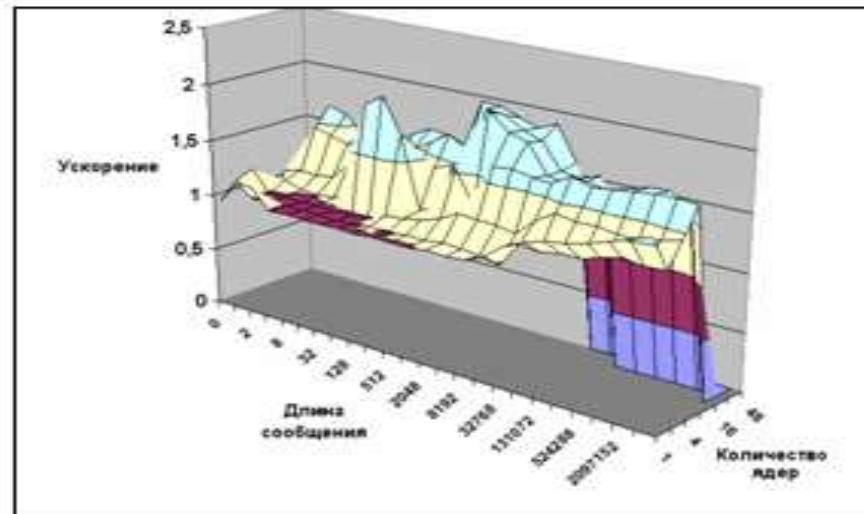
Серверная плата ПТК (СПбГПУ)



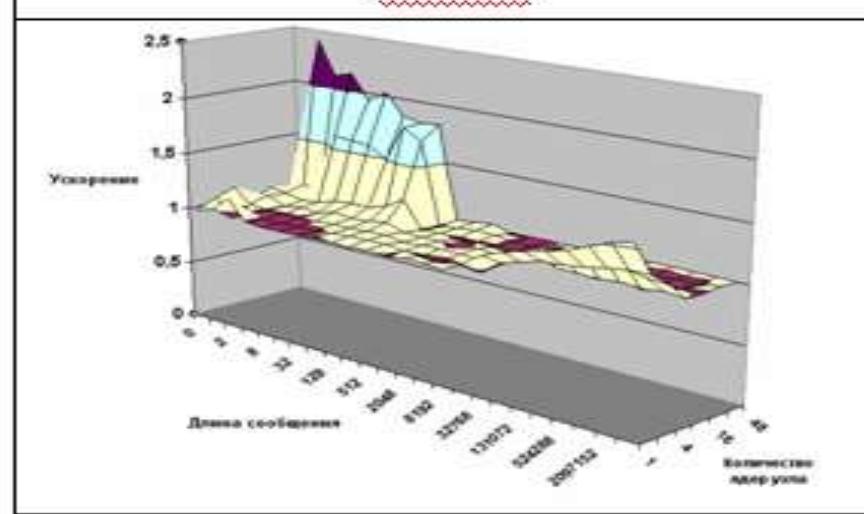
Ускорение операций “точка-точка” на 2-х и 3-х адаптерной установке



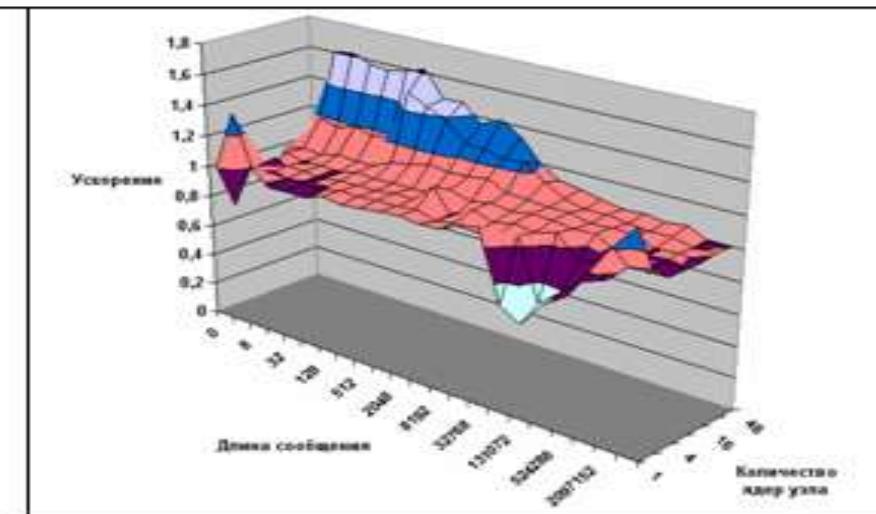
Ускорение коллективных операций на 2-х адаптерной установке



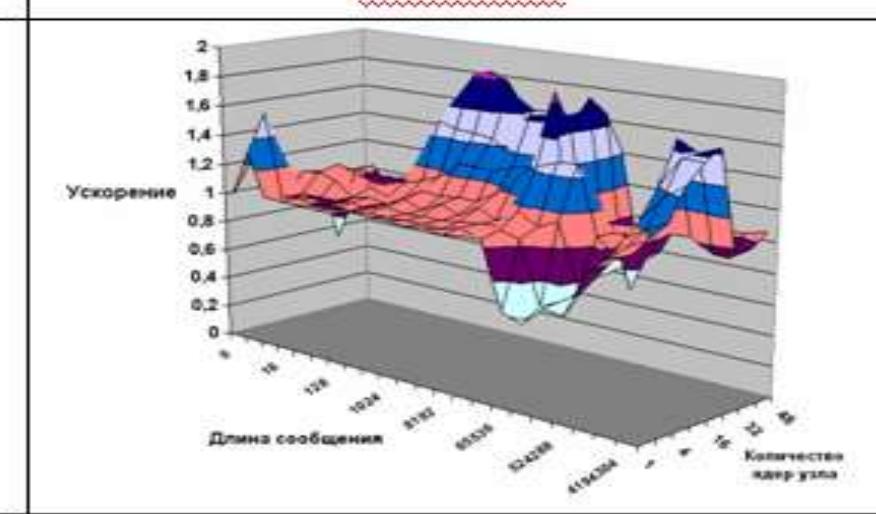
Alltoall



Allgather

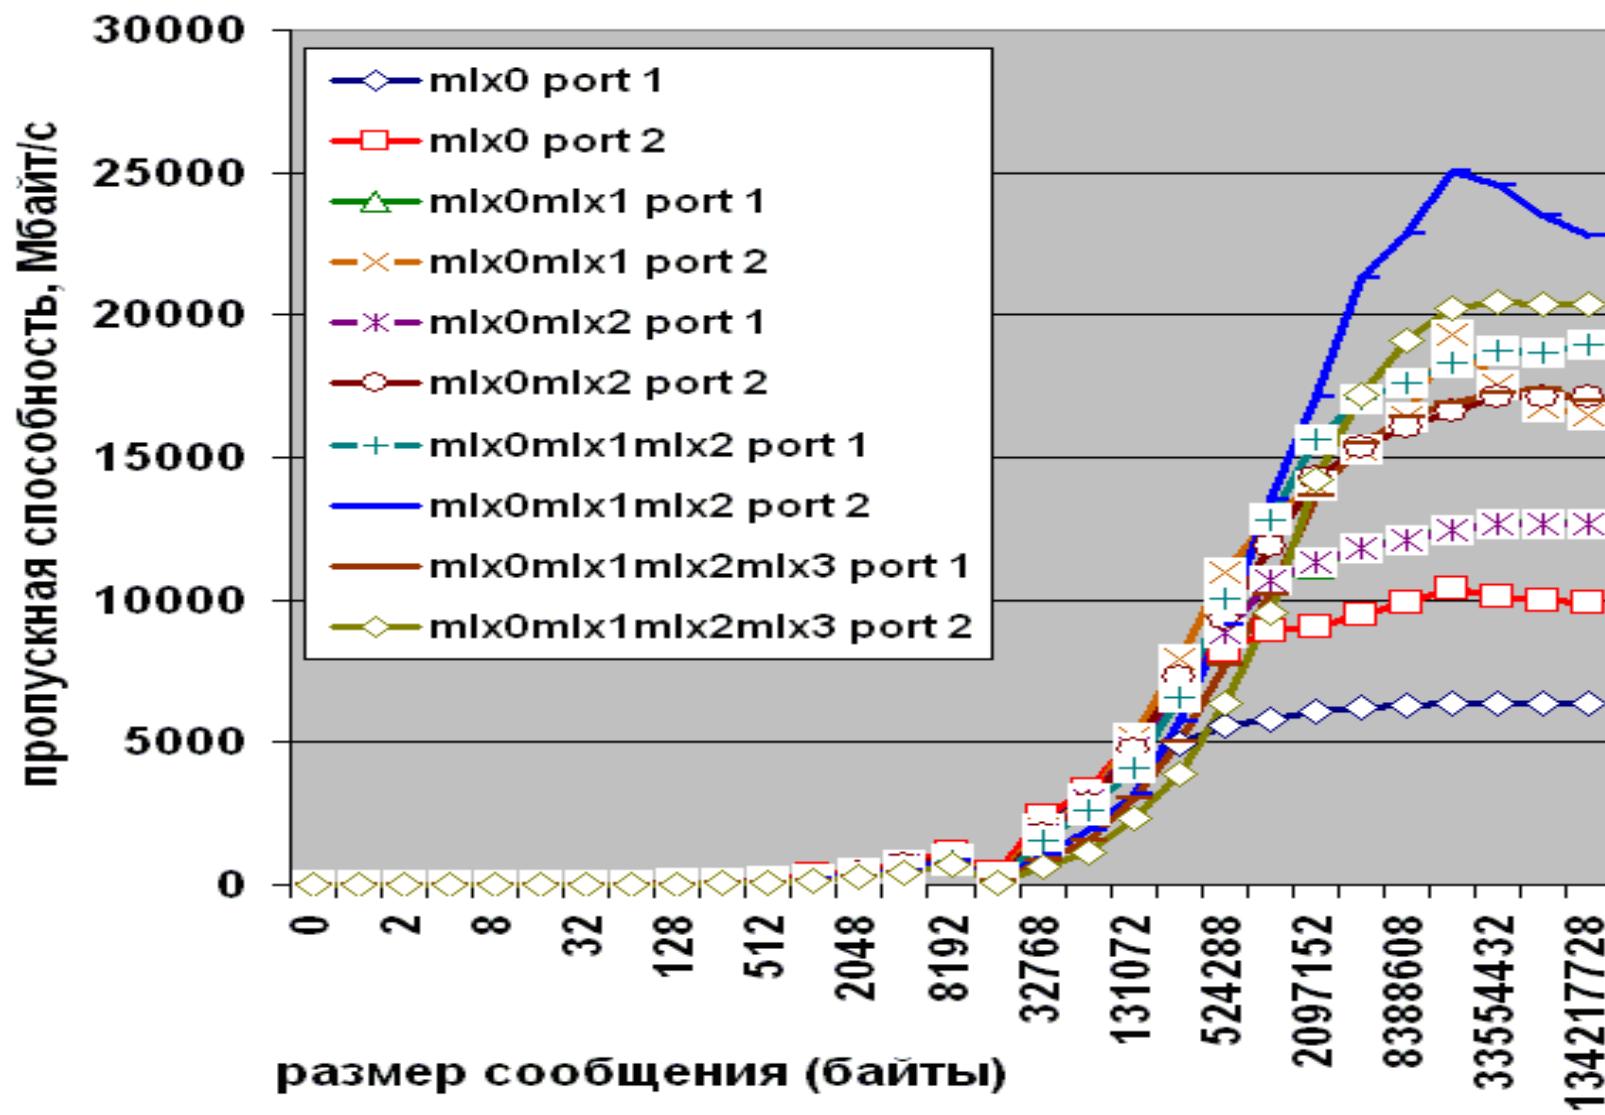


Allreduce



ReduceScatter

PingPong на 2-х, 3-х и 4-х адаптерной установке (2-х портовые адаптеры Connect-IB)



Экзафлопс (эволюционные и инновационные СКТ)

Россия – только эволюционные СКТ
?

10 актуальных проблем разработки экзафлопсных суперкомпьютеров в США

1. Энергоэффективность - создание энергоэффективных схем процессоров, маршрутизаторов коммуникационных сетей, технологий обеспечения питанием и технологий охлаждения.
2. Технологии соединений как внутри вычислительных узлов, так и между вычислительными узлами – увеличение производительности и сокращение задержек передачи данных, достижение энергоэффективности в линиях связи коммуникационных сетей и интерфейсах, наиболее важный показатель – снижение энергопотребления и повышения быстродействия обращений к памяти удаленных узлов (RDMA).
3. Технологии оперативной памяти – интеграция новых улучшенных технологий памяти для повышения емкости при повышении плотности размещения запоминающих элементов и сокращения их стоимости, снижение задержек выполнения операций с памятью, повышение их сложности и локализации, повышение пропускной способности даже для обращений с большой мелкозернистостью, т.е. когда обращения происходят к небольшим участкам памяти, а не к блокам большого объема.

10 актуальных проблем разработки экзафлопсных суперкомпьютеров в США

4. Создание масштабируемого (при увеличении параллелизма) системного программного обеспечения в виде операционных систем нового типа и систем поддержки выполнения программ (run-time систем), обеспечивающего высокий параллелизм уровня 10^9 (основной прирост, до трех порядков, ожидается непосредственно внутри вычислительного узла, а междуузловой – на порядок), энергоэффективность за счет глубокого проникновения в управление работой оборудования и отказоустойчивость.

5. Системы программирования для пользователей – создание новых систем программирования, которые обеспечивают: создание эффективных с массовым параллелизмом программ, прозрачную для пользователя работу с иерархической глобально адресуемой памятью с обеспечением как эффективных удаленных обращений к памяти, так и локализацию данных при вычислениях и вычислениях при данных; высокую многоуровневую отказоустойчивость.

6. Управление данными – создание хранилищ данных, программного обеспечения, которые бы справились с объемами и интенсивностью поступающих данных, их обработкой и хранением, ожидаемым разнообразием типов данных

10 актуальных проблем разработки экзафлопсных суперкомпьютеров в США

7. Создание экзасштабных алгоритмов – переформулирование научных проблем и реконструирование или переработка алгоритмов их решения с целью эффективного выполнения на создаваемых суперкомпьютерах экзафлопсного класса.

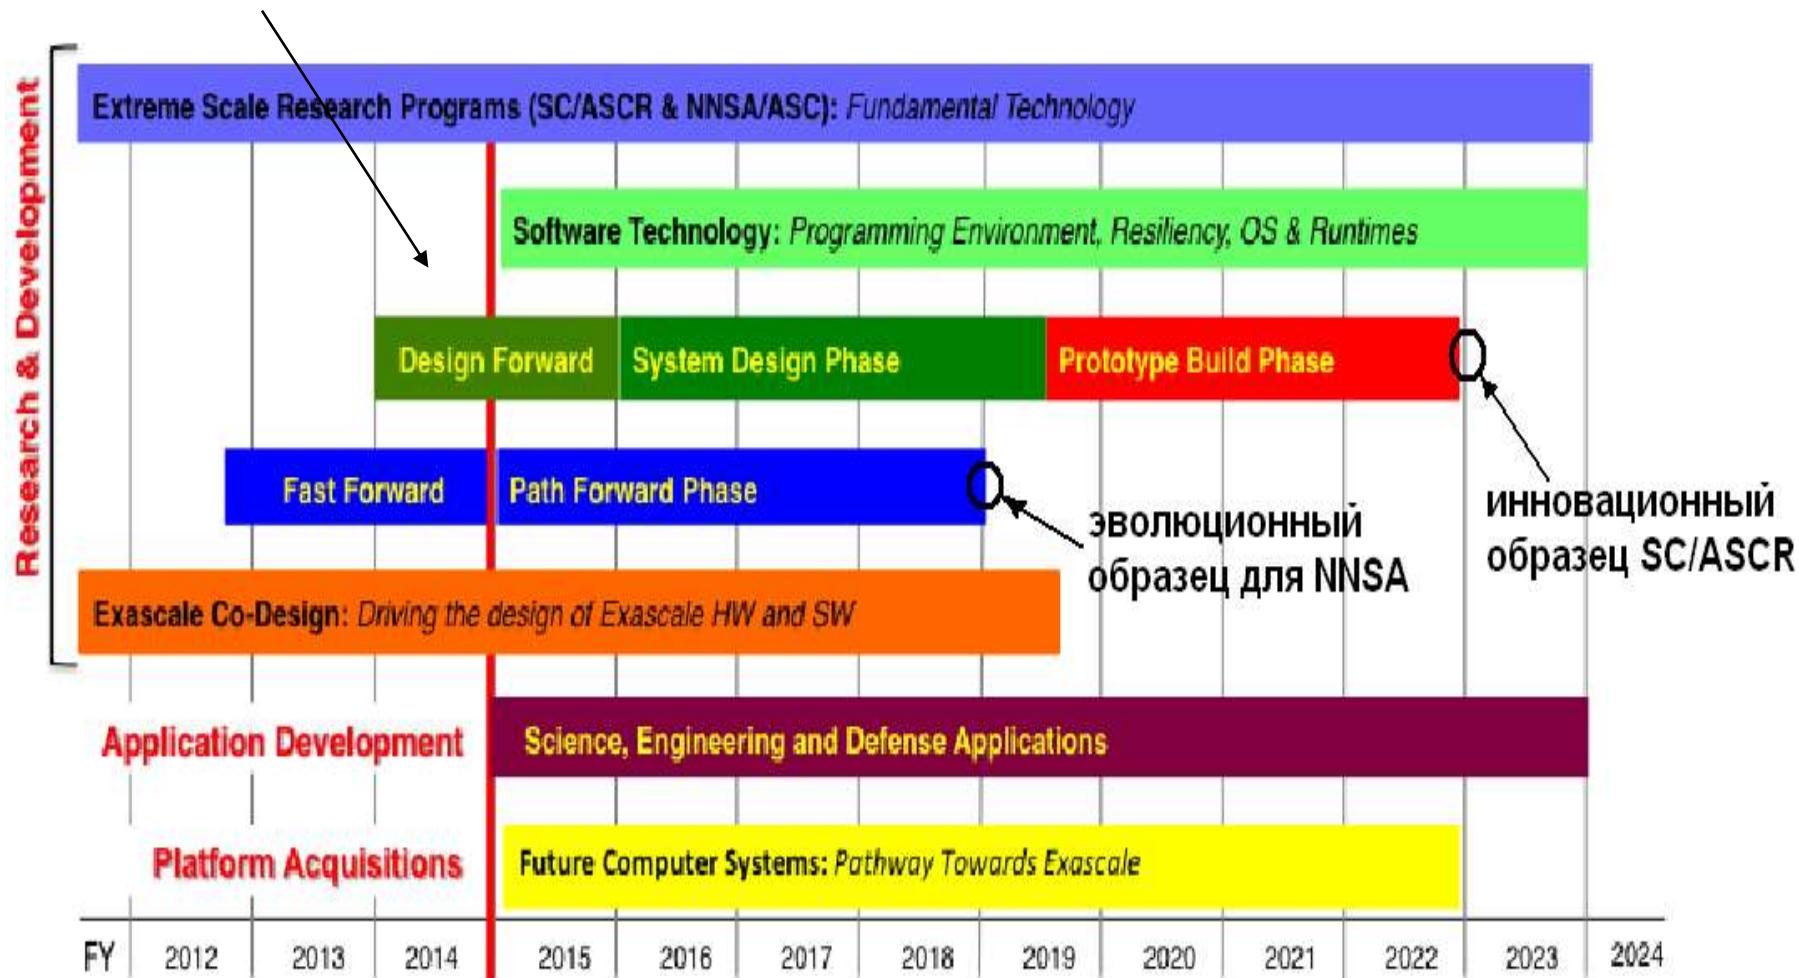
8. Создания алгоритмов автоматизации принятия решений по получаемым на экзафлопсных суперкомпьютерах результатам, что связано с оптимизацией принятия инженерных решений при создании сложных технических изделий, извлечением знаний из результатов научных расчетов и поступающих данных от сенсоров и физических установок.

9. Обеспечение как отказоустойчивости, так и достоверности вычислений в условиях наличия сбоев и отказов оборудования, ошибок программ и информационных не повторяемости результатов вычислений.

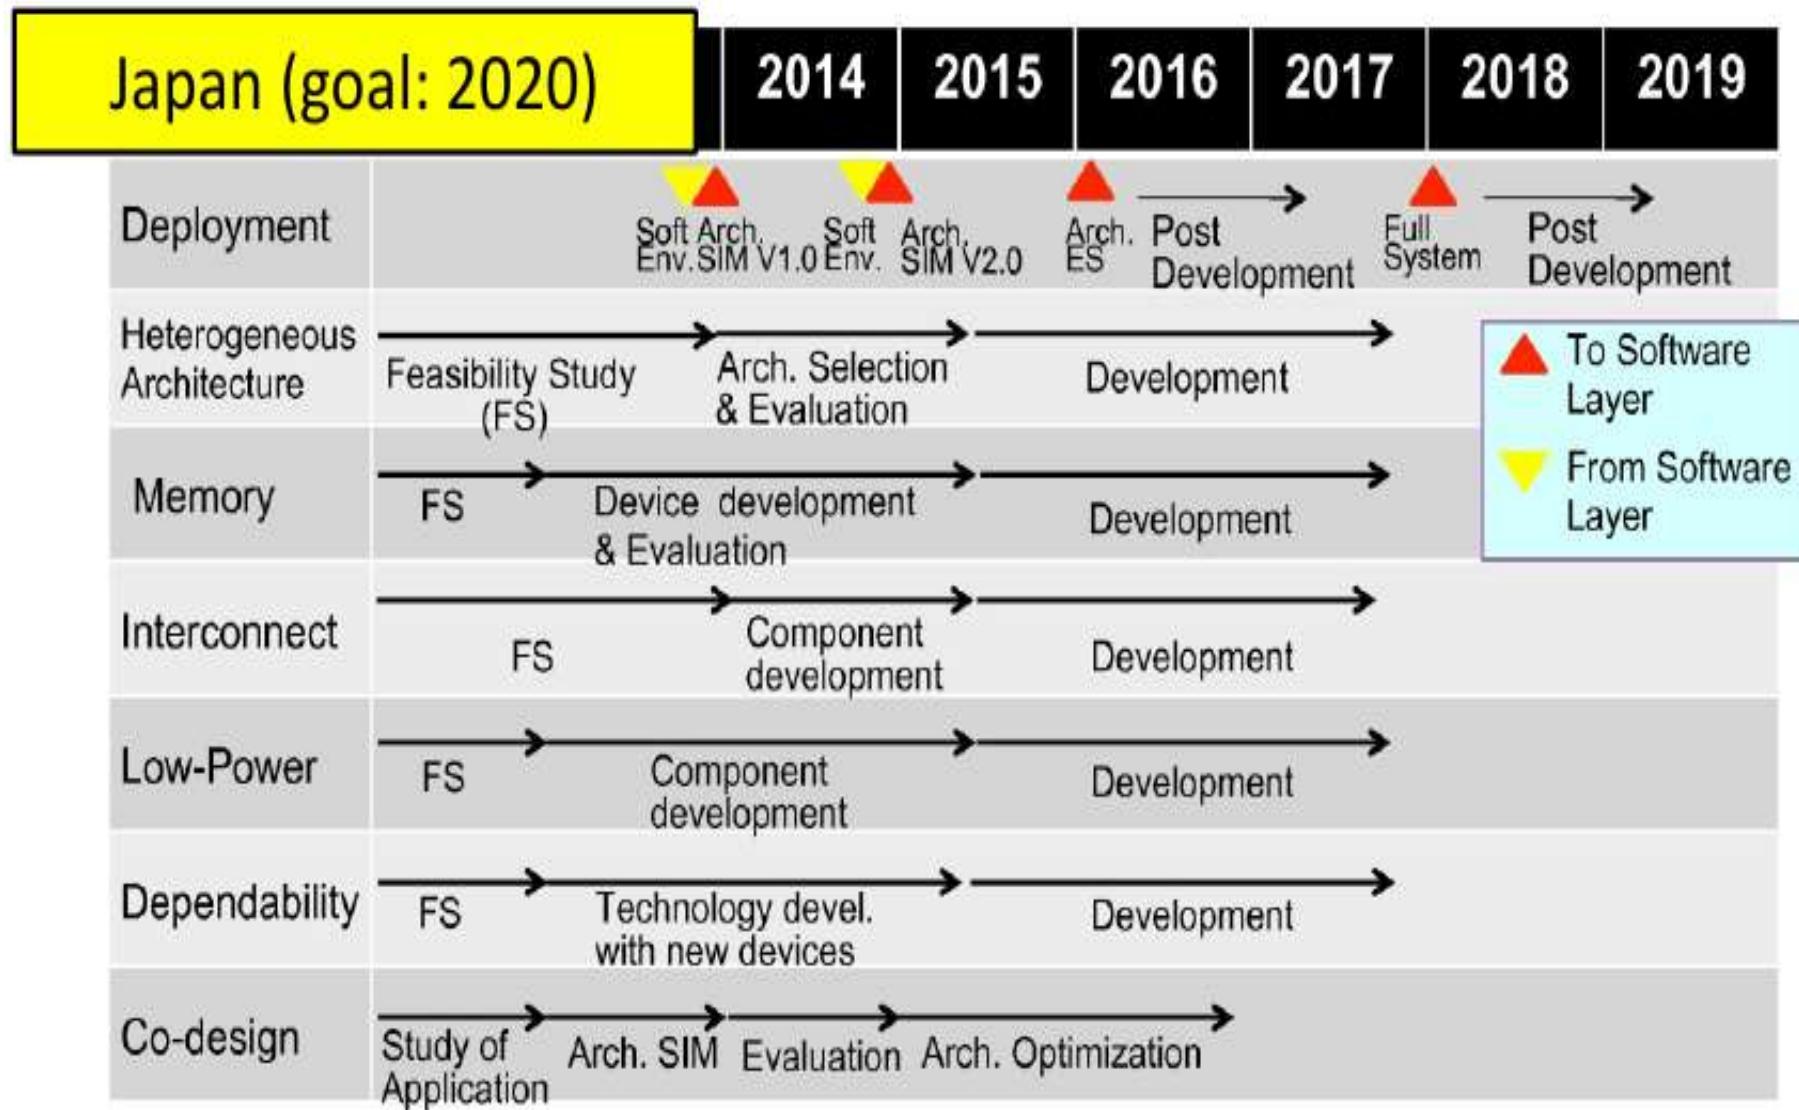
10. Повышение производительности разработки прикладных программ.

Дорожная карта создания экзафлопсных суперкомпьютеров DoE США

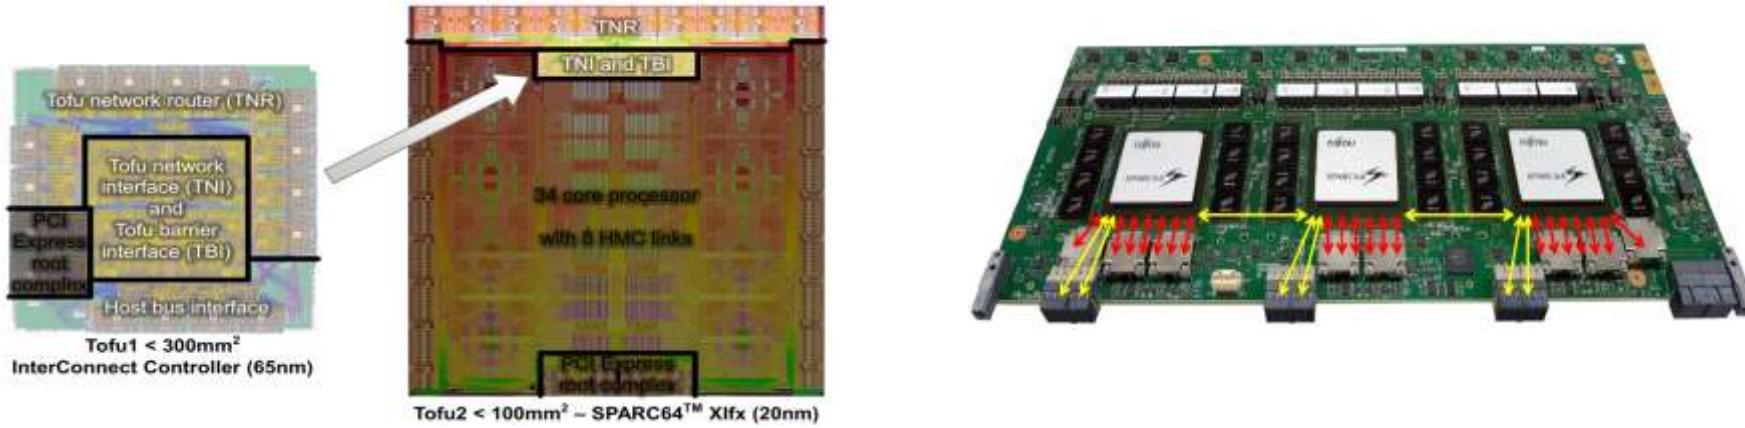
- ORNL Titan, Cray XK7, 27 PF
- LLNL Sequoia, IBM BG/Q 20 PF
- ANL Mira, IBM BG/Q, 10 PF
- LBNL Edison, Cray XC30, 2 PF
- LANL Cielo, Cray XE6, 1.1 PF



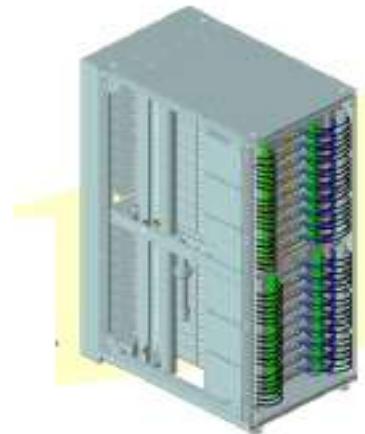
Дорожная карта создания экзаслопных суперкомпьютеров Японии



Новый вариант К-компьютера (Fujitsu, 2015 год)



2U chassis
12 nodes

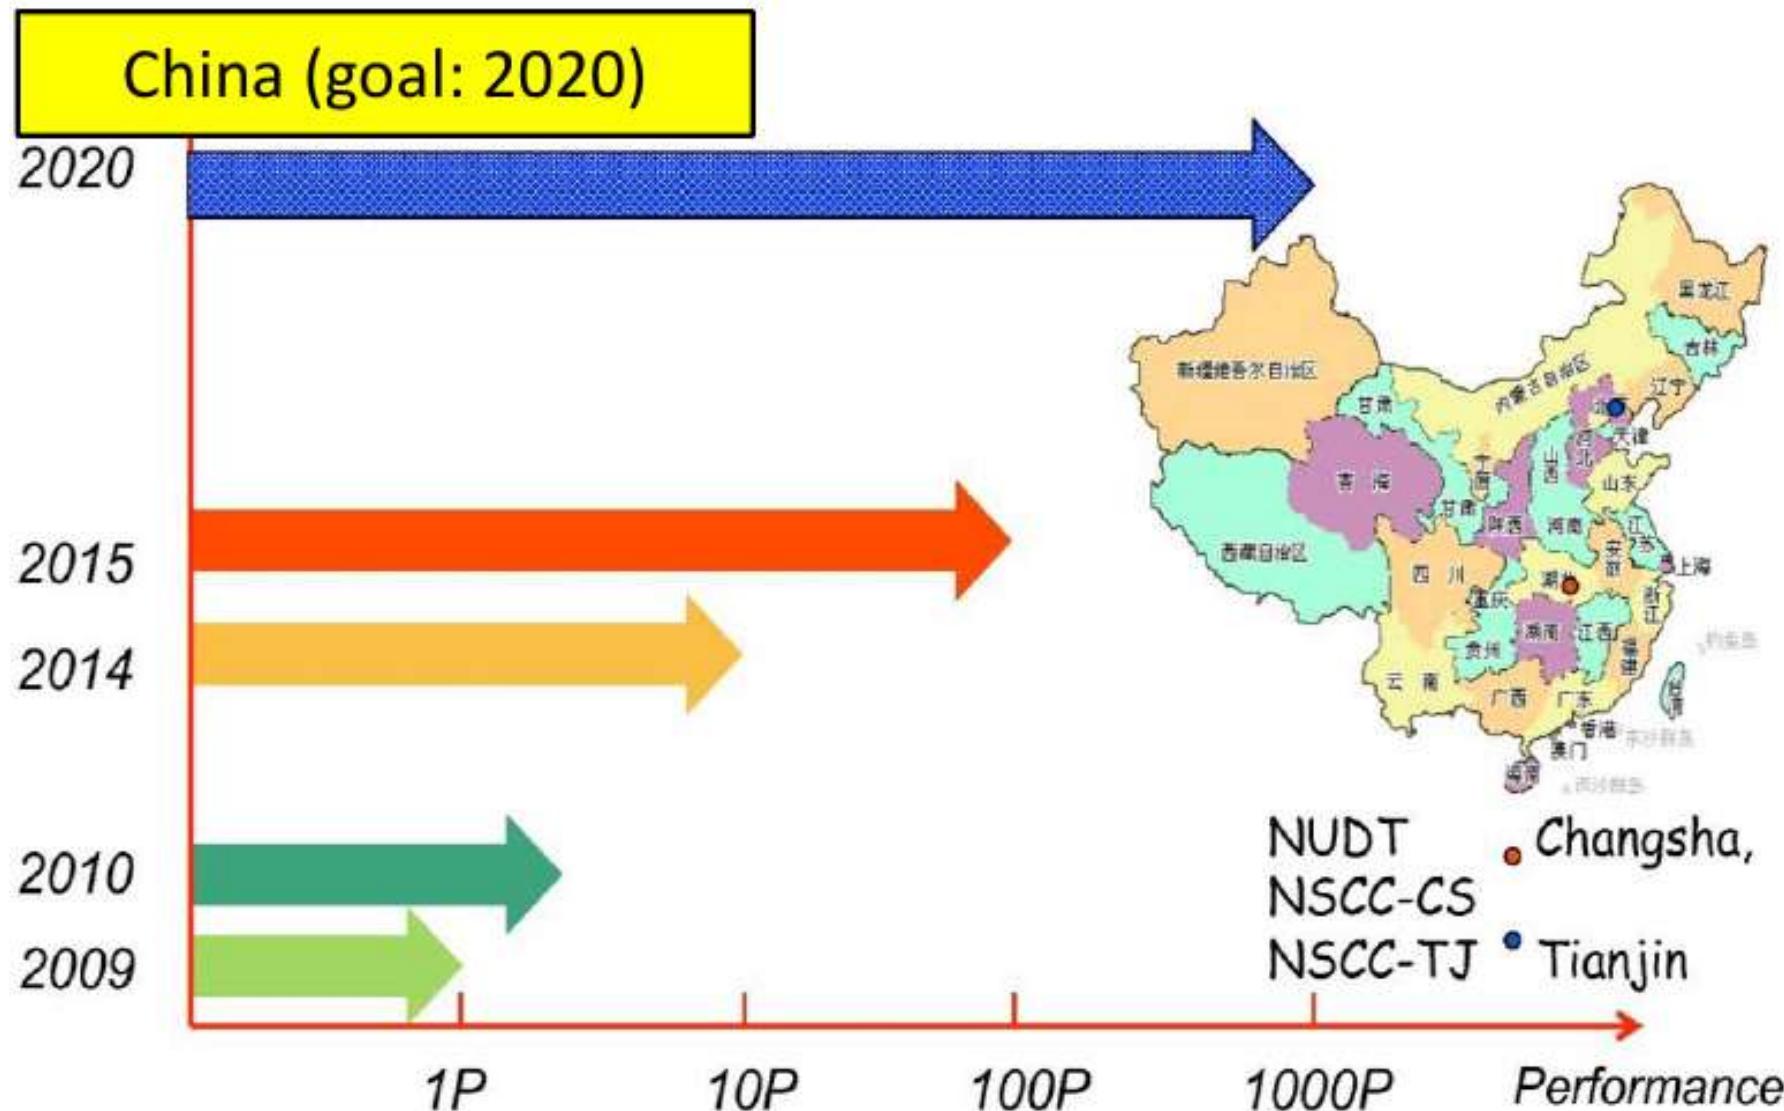


19-inch rack
216 nodes



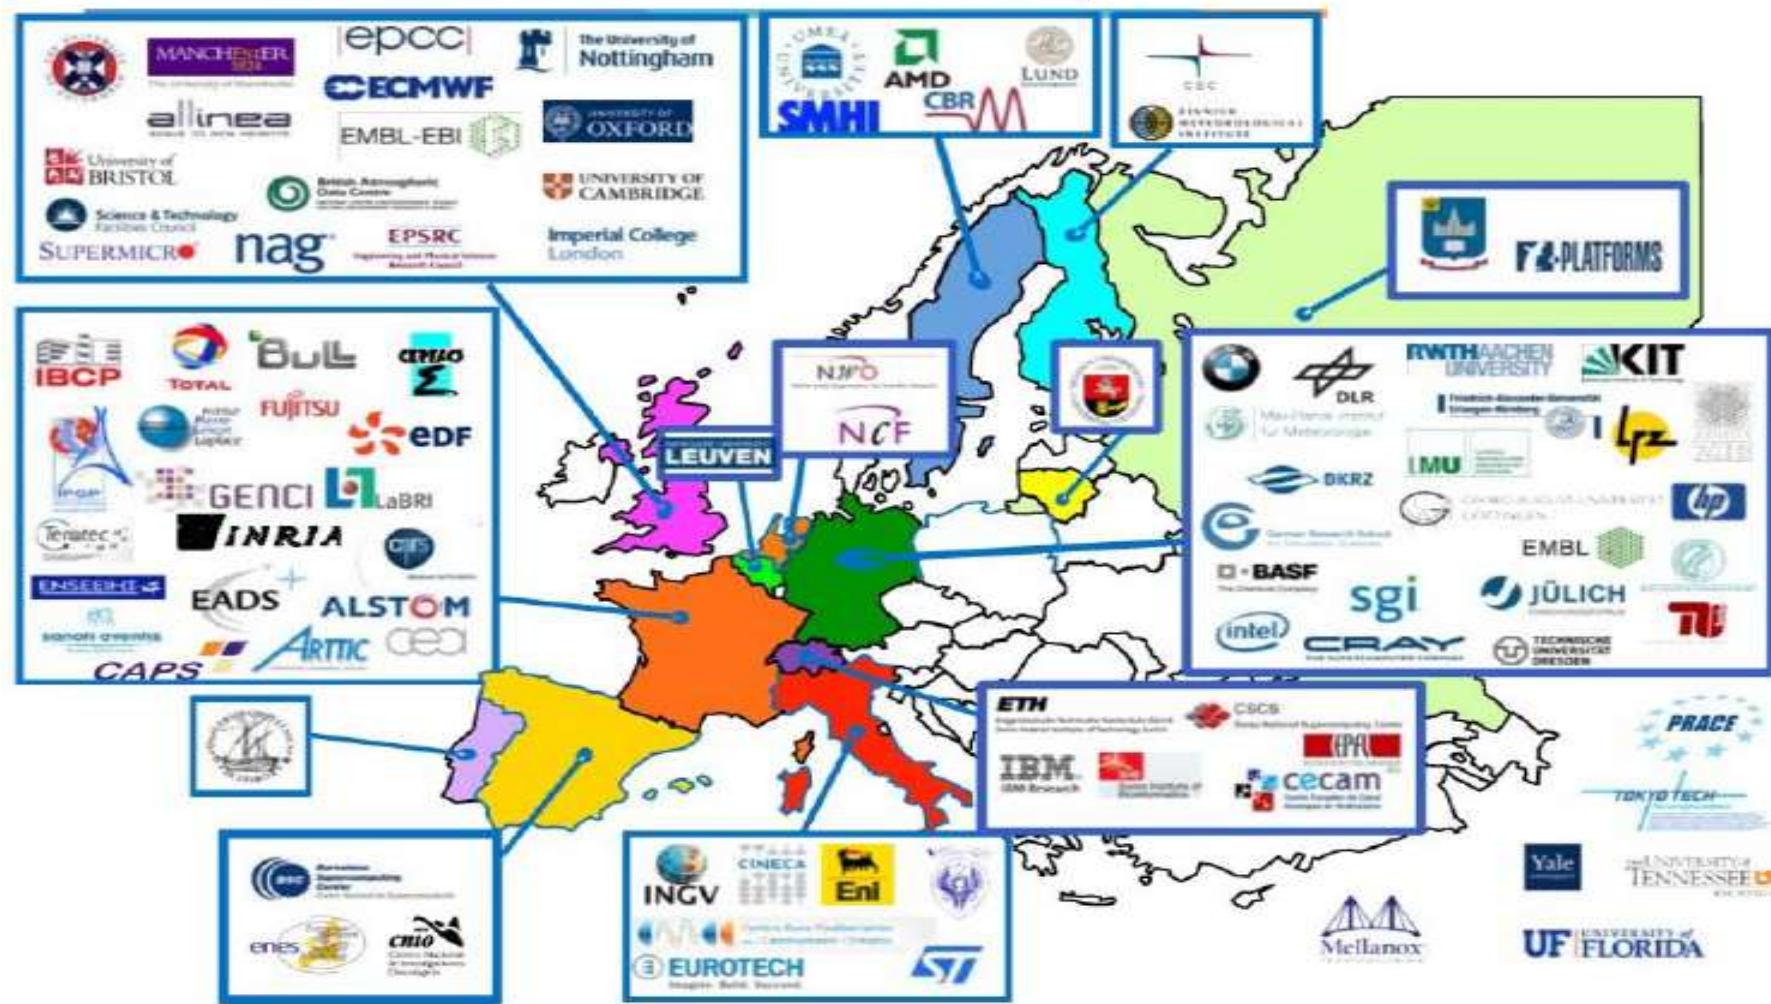
Post-FX10 System
Petaflops per 5 racks

Дорожная карта создания экзаслопных суперкомпьютеров Китая



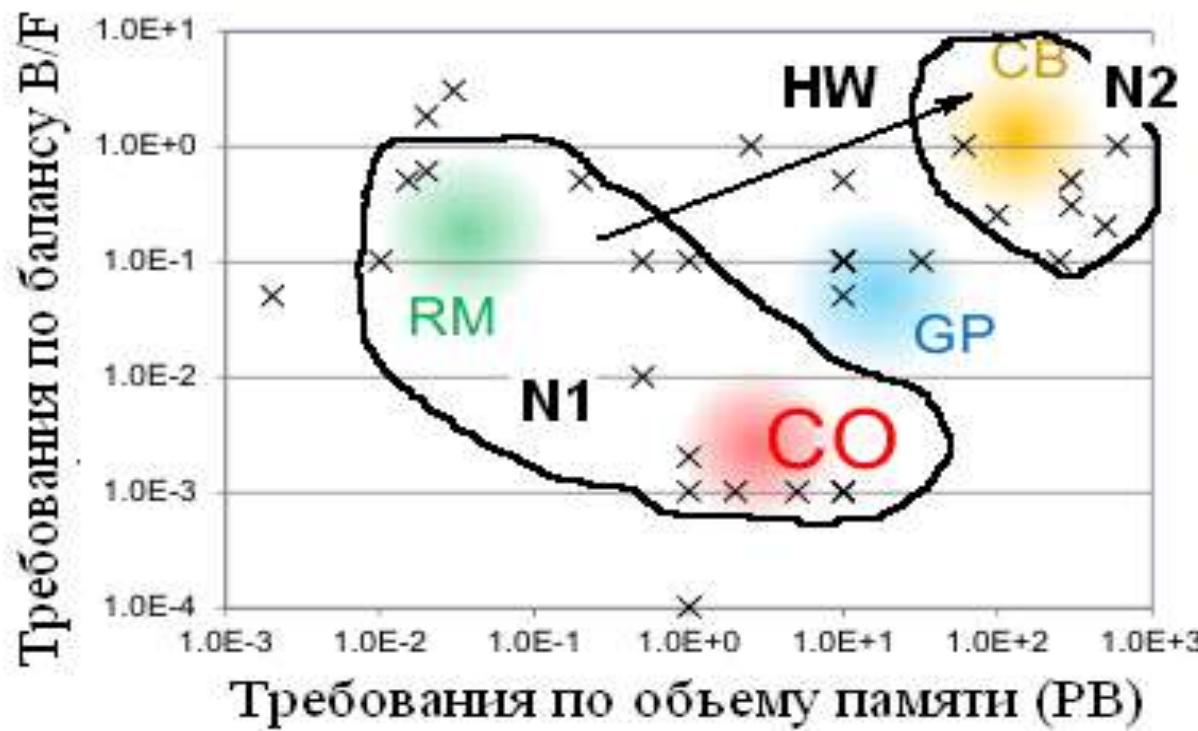
Участники работ по экзафлопсной тематике в Европе

European Union (goal: 2020)



Российские инновационные СКТ (примеры из проекта МГВС РАН)

Предложения по стратегии и тактике импортозамещения в контексте развития инновационных СКТ

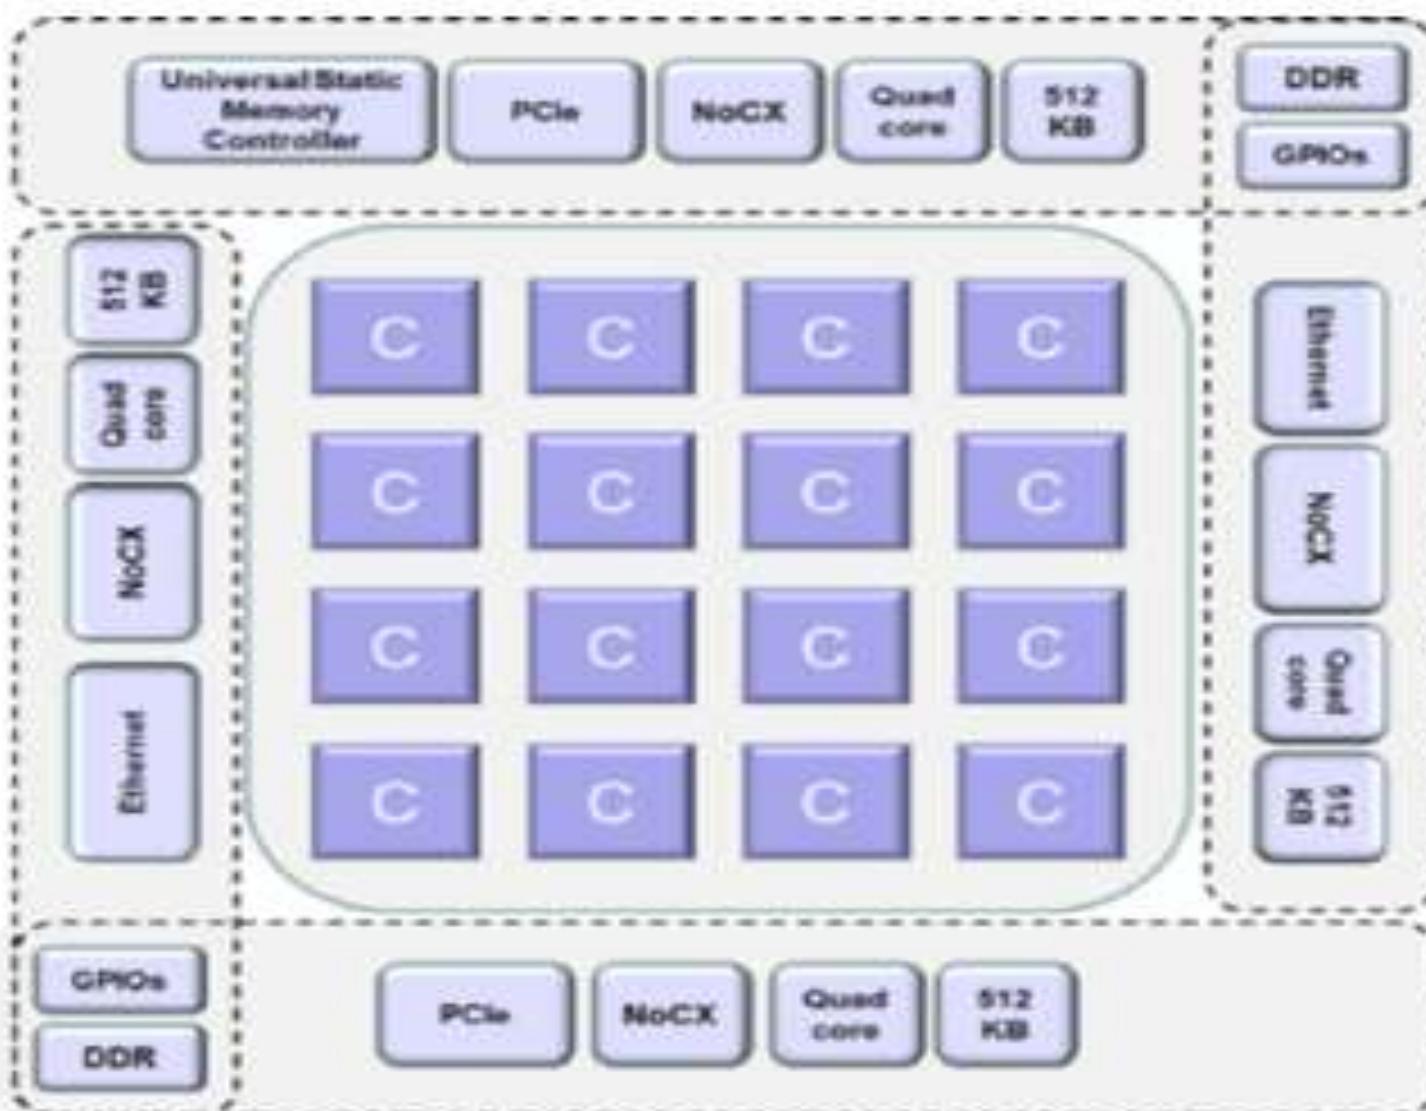


N1 - упрощенные проблемно-ориентированные КМОП-микропроцессоры, далее - их реализация на пост-Муровской ЭКБ (TSV, нанофотоника, RSFQ, QCA (????))

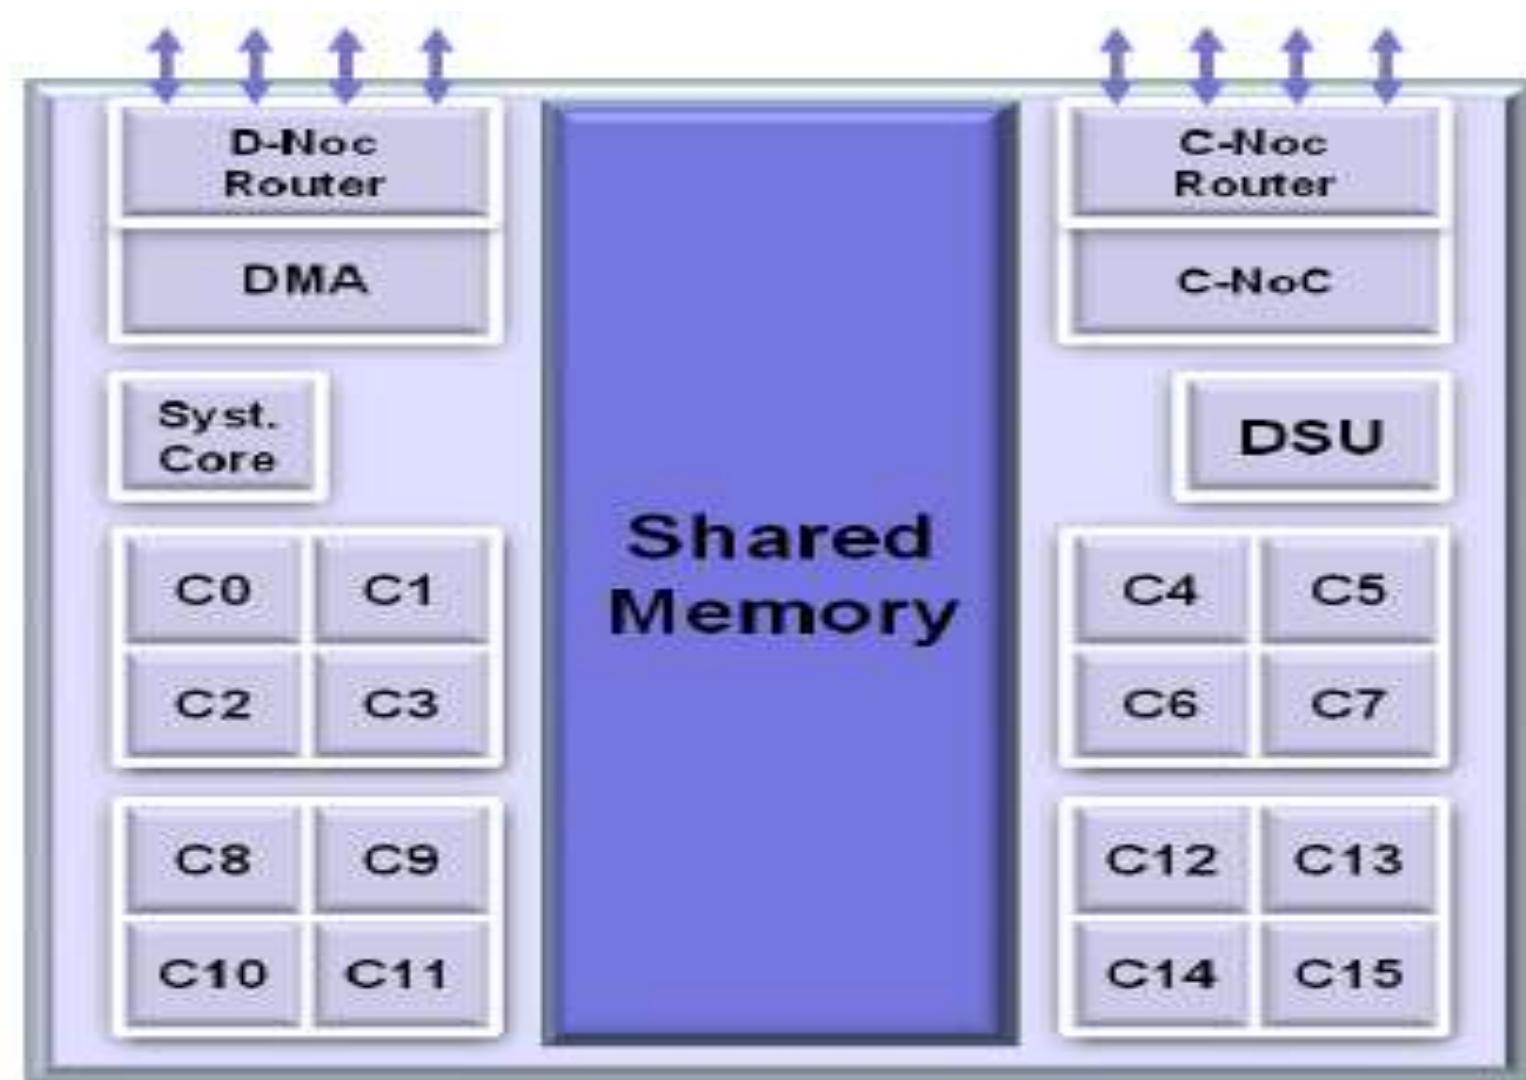
N2 - эмуляция HPGAS и массовой мультиитредовости на GP-классе, микропроцессоры для СВ-класса можно создать посредством модернизации проблемно-ориентированных микропроцессоров для суперкомпьютеров RM- и CO-класса

Разработка упрощенных проблемно-ориентированных микропроцессорных СБИС (примеры зарубежных изделий)

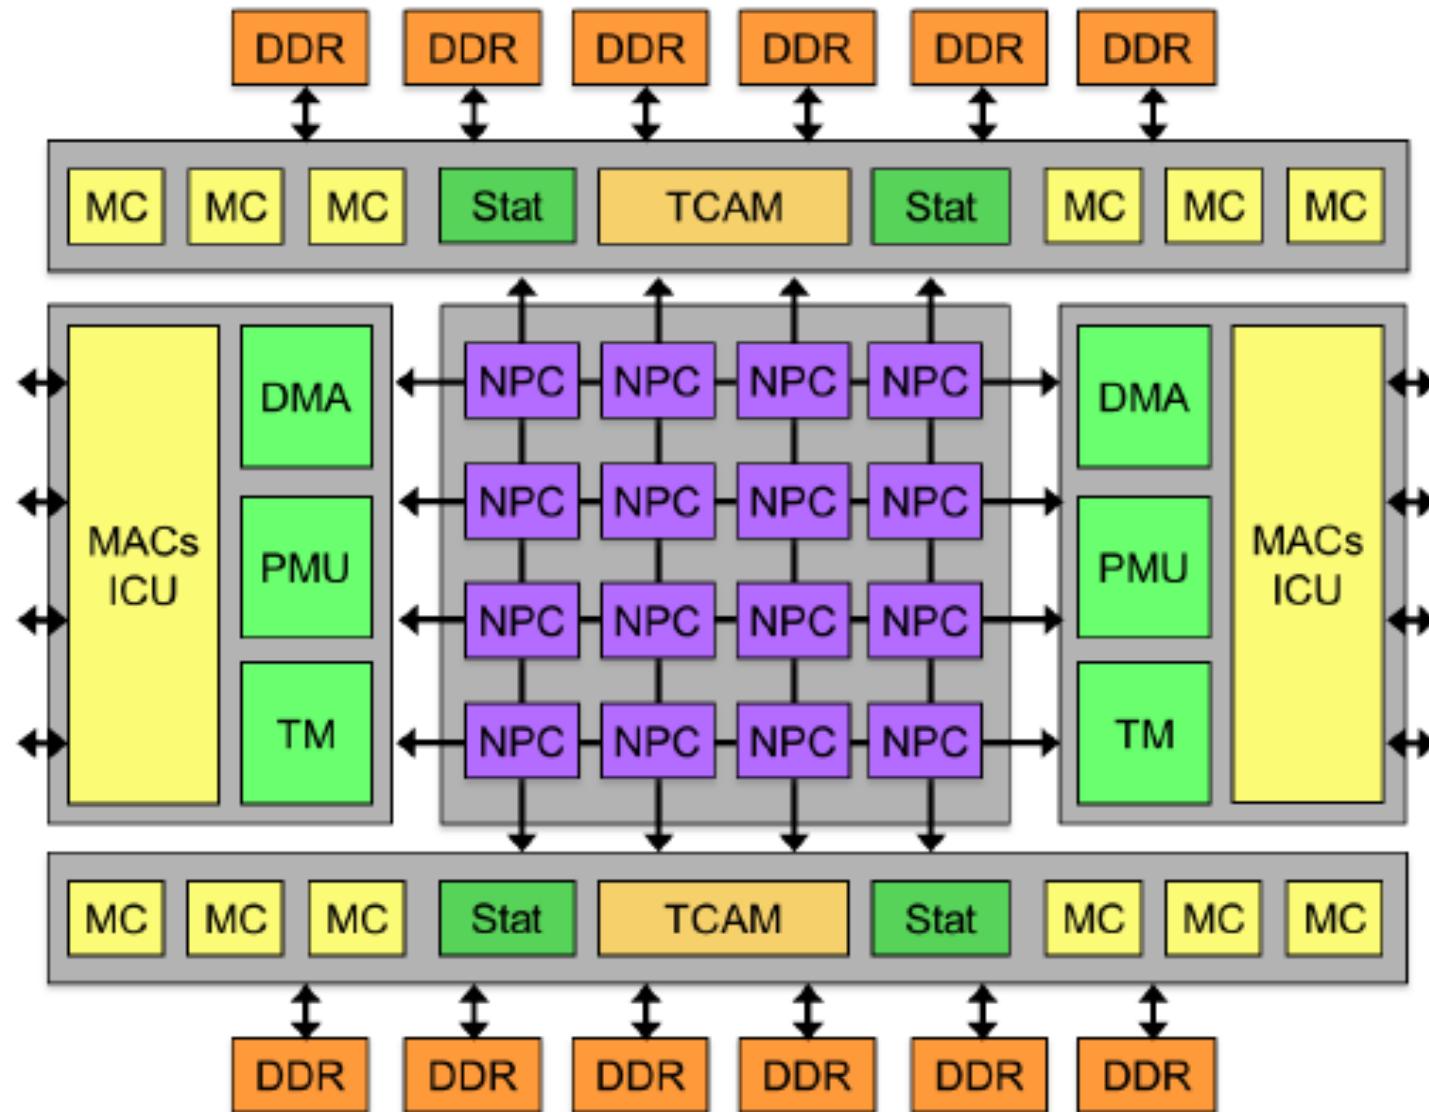
Микропроцессор MPAA-256, фирма Kalray (Франция)



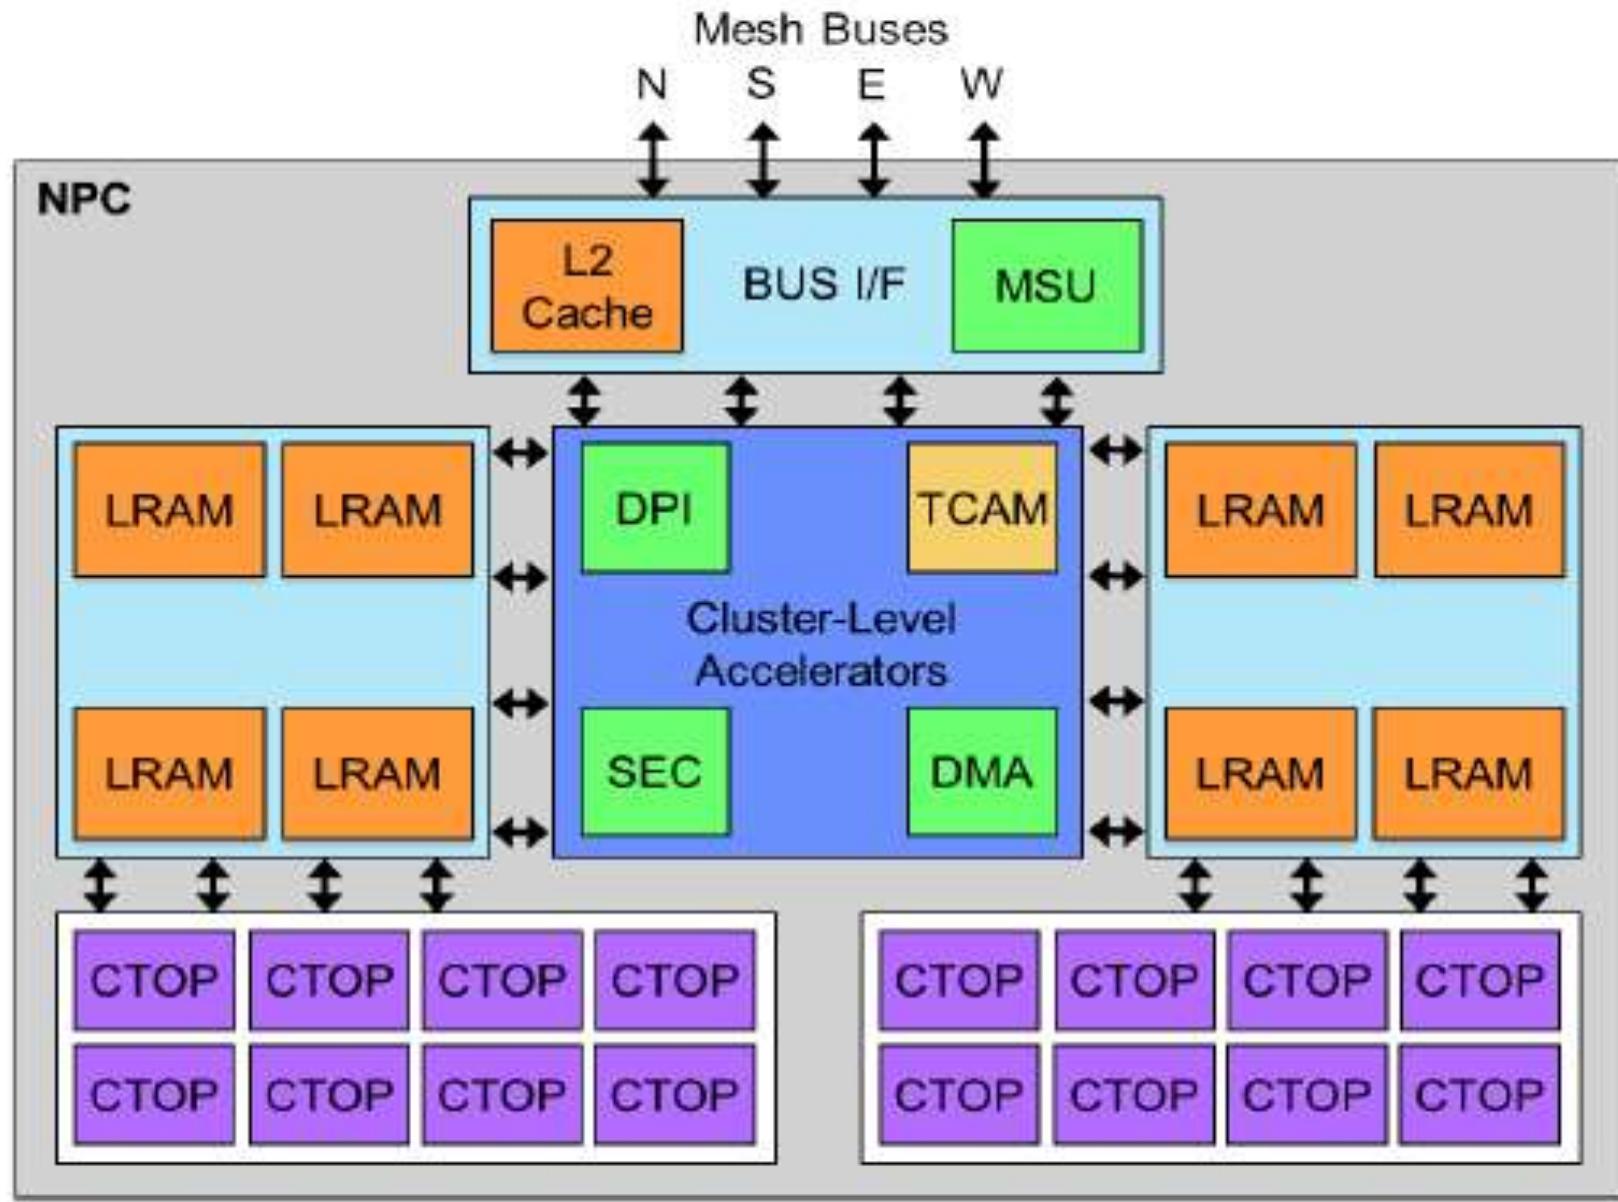
Кластер микропроцессора МРРА-256 (16 VLIW-ядер + ядро управления)



Сетевой микропроцессор NPS-400 фирмы EZChip (Израиль)



Кластер NPC микропроцессора NPS-400

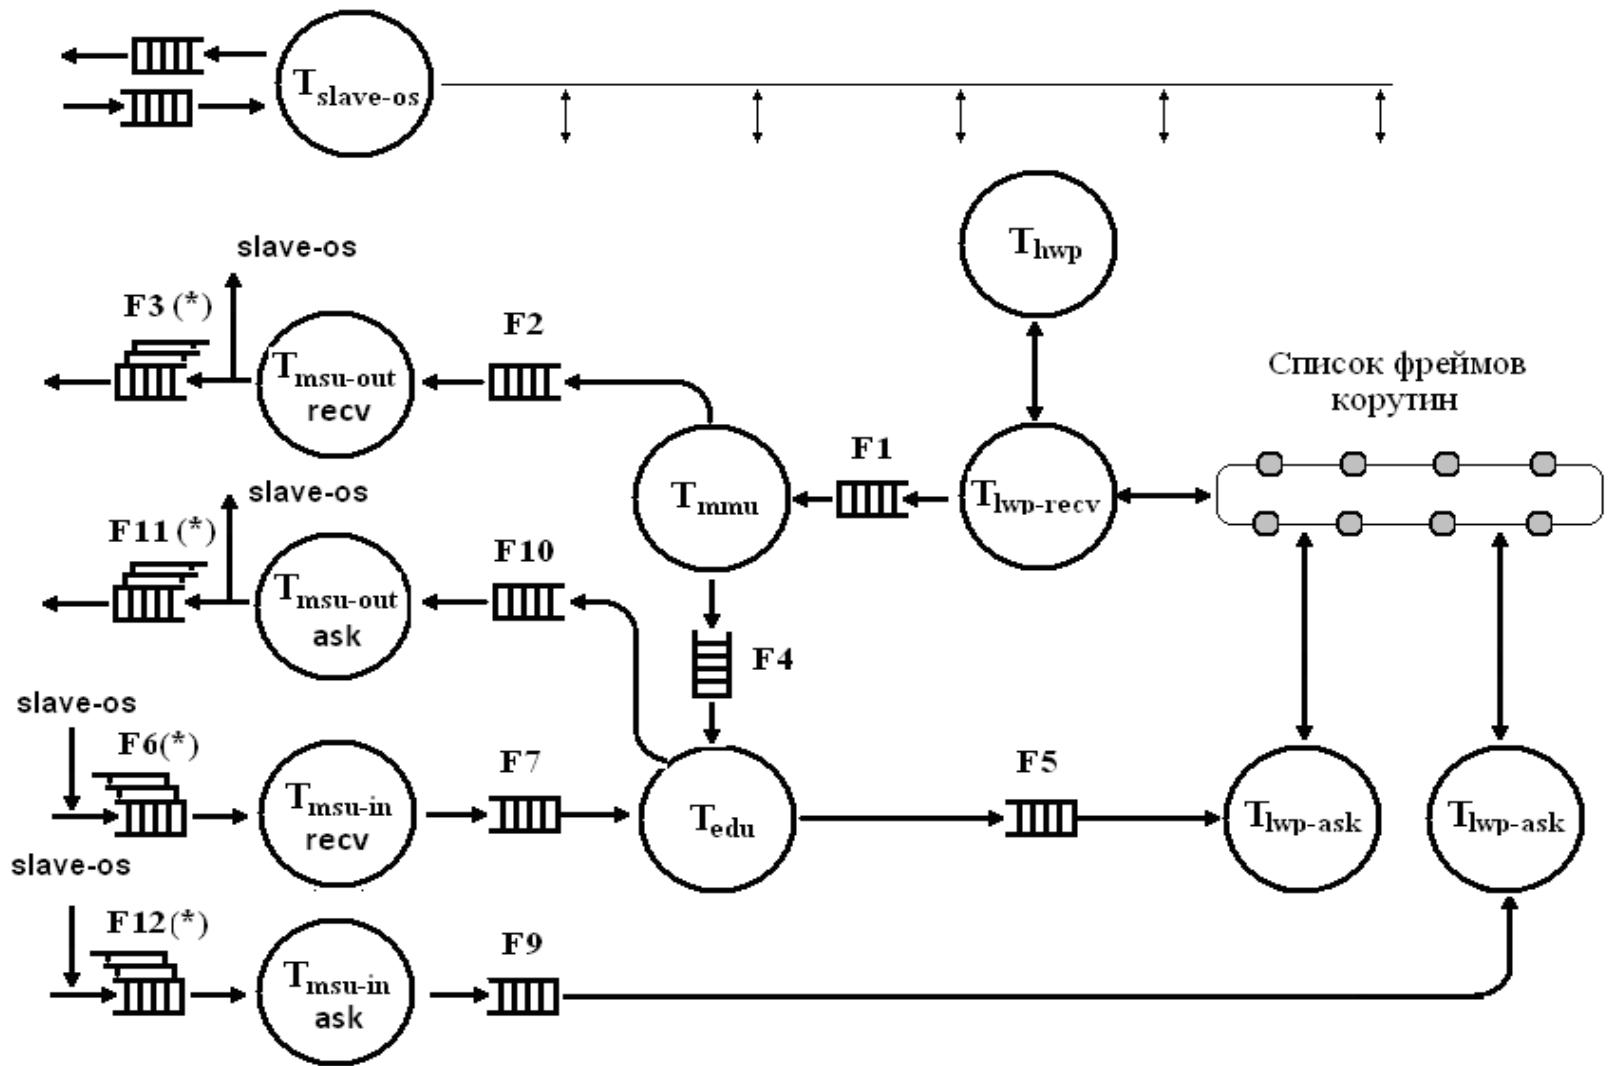


**Эмуляция HPGAS и массовой
мультитредовости на кластерных
суперкомпьютерах.**

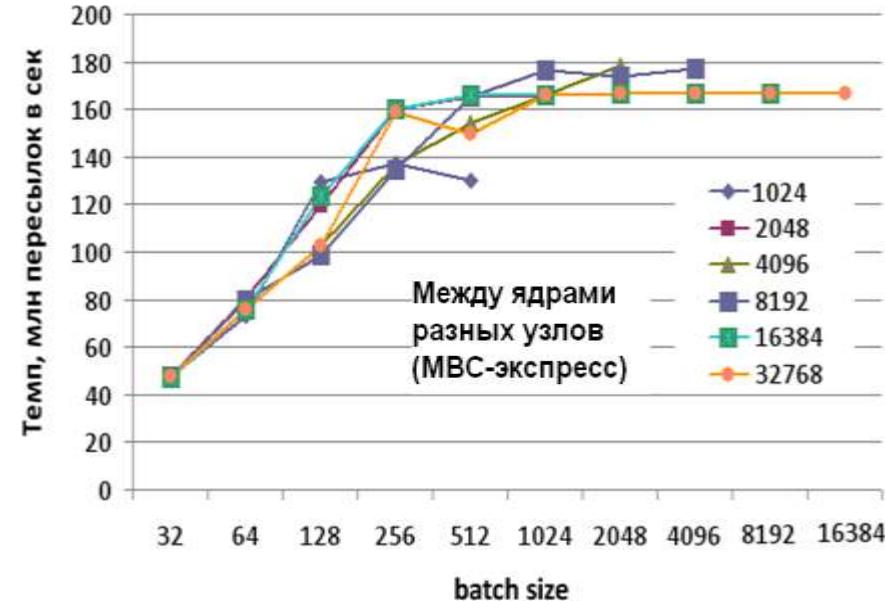
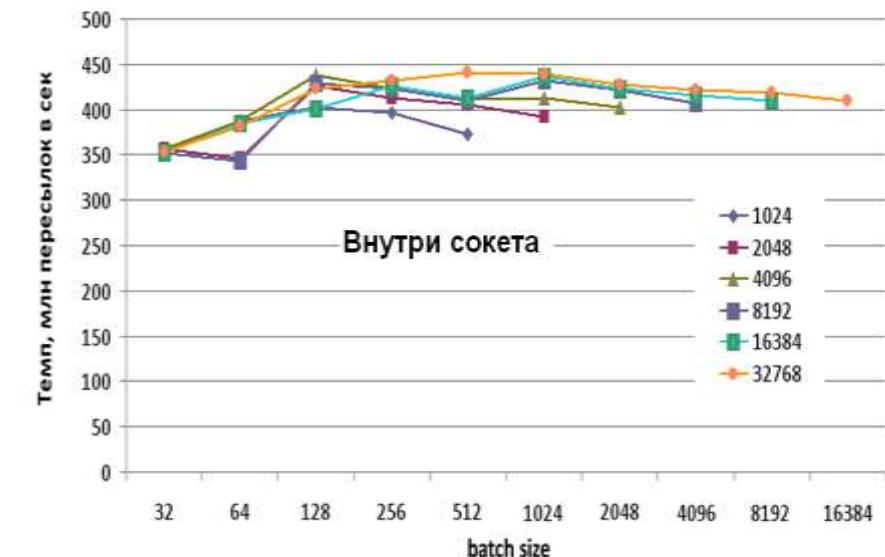
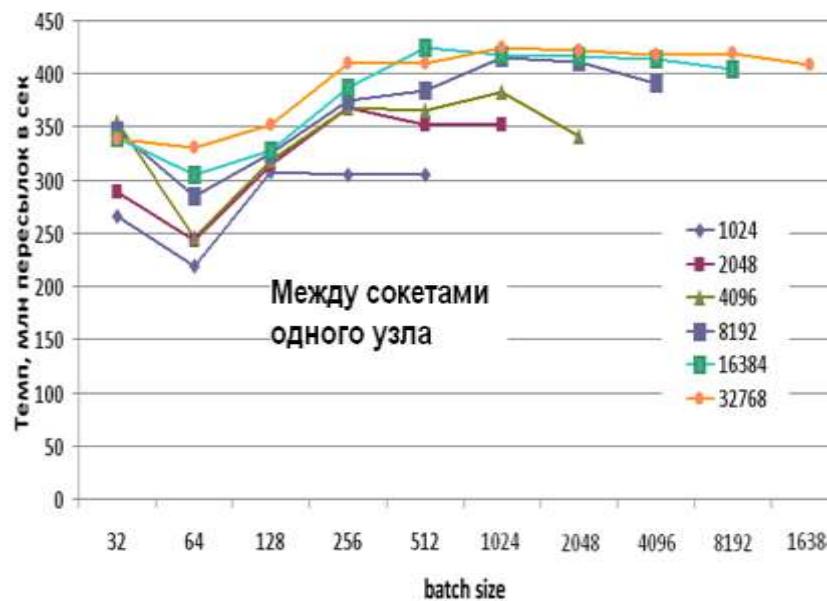
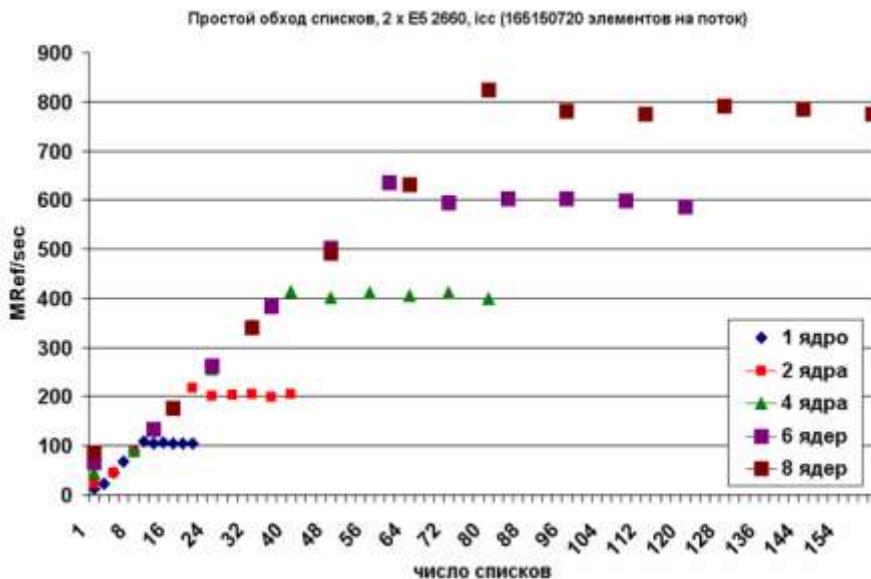
**Модели параллельных программ
для экзафлопсных машин.**

Функциональный суперкомпьютер

Уточненная схема логического узла проекта HPGAS/МТ



Результаты экспериментов по HPGAS/МТ



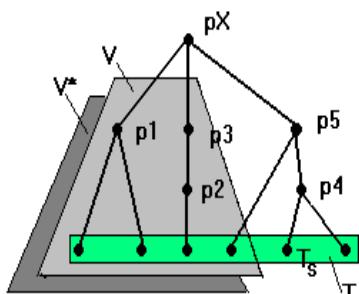
Крупнозернистое распараллеливание программ – одновременное выполнение функций.

Программа

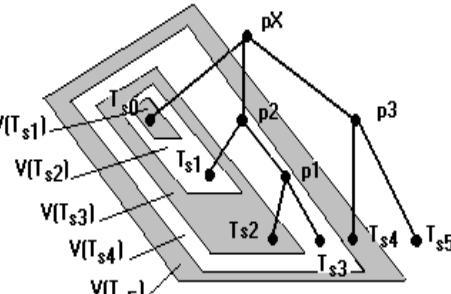
$$\begin{aligned}
 & \S 1 kfe_1 + e_2 > kfe_1 \perp, kfe_2 \perp, + \\
 & \S 2 kfe_1 * e_2 > kfe_1 \perp, kfe_2 \perp, * \\
 & \S 3 kfe_1 > e_1
 \end{aligned} \tag{1}$$

Последовательное выполнение

- шаг 1. $kfA * B + C * D \perp$
- шаг 2. $kfA * B \perp, kfC * D \perp, +$
- шаг 3. $kfA \perp, kfB \perp, *, kfC * D \perp, +$
- шаг 4. $A, kfB \perp, *, kfC * D \perp, +$ (2)
- шаг 5. $A, B, *, kfC * D \perp, +$
- шаг 6. $A, B, *, kfC \perp, kfD \perp, *, +$
- шаг 7. $A, B, *, C, kfD \perp, *, +$
- шаг 8. $A, B, *, C, D, *, +$



Дерево вызовов функций (конкретизаций).



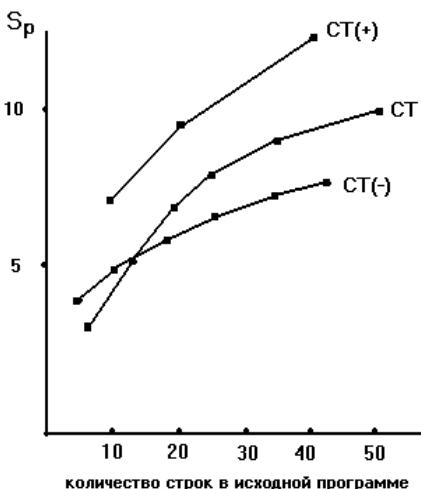
Информационные зависимости на дереве конкретизаций.

Параллельное выполнение

- шаг 1. $kfA * B + C * D \perp$
- шаг 2. $kfA * B \perp, kfC * D \perp, +$ (3)
- шаг 3. $kfA \perp, kfB \perp, *, kfC \perp, kfD \perp, *, +$
- шаг 4. $A, B, *, C, D, *, +$

```

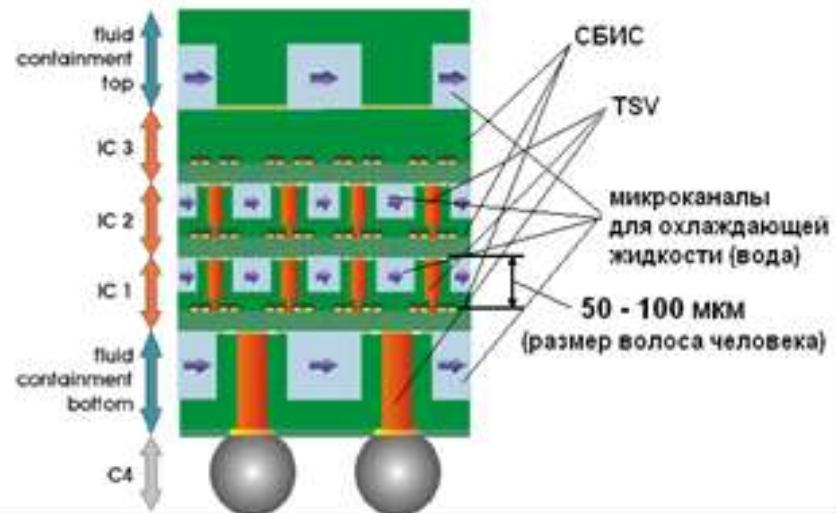
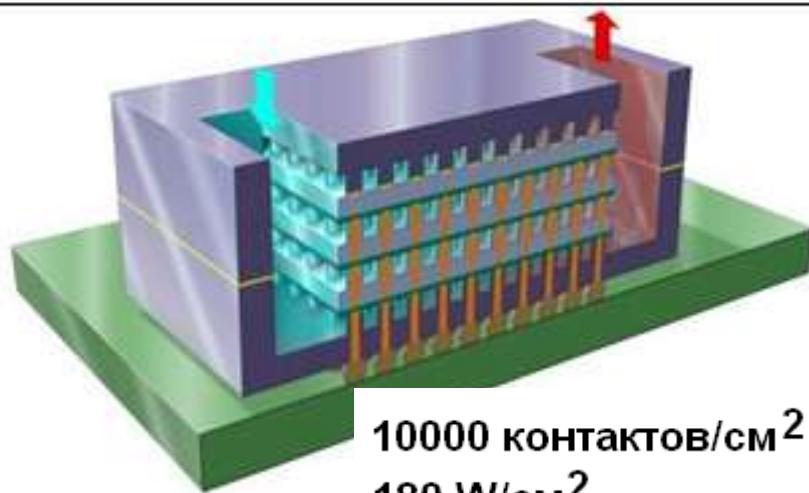
Тест CT(-)  real A,B,C
                B = C+A
                ...
                B = C+A
                end
Тест CT    real A,B,C
                A = B + C/(C*2.3-B)
                B = C+A
                ...
                A = B + C/(C*2.3-B)
                B = C+A
                end
Тест CT(+)  real A,B,C
                A = B + C/(C*2.3-B)
                ...
                A = B + C/(C*2.3-B)
                end
  
```



Пример совмещения проектирования элементов одной левой части

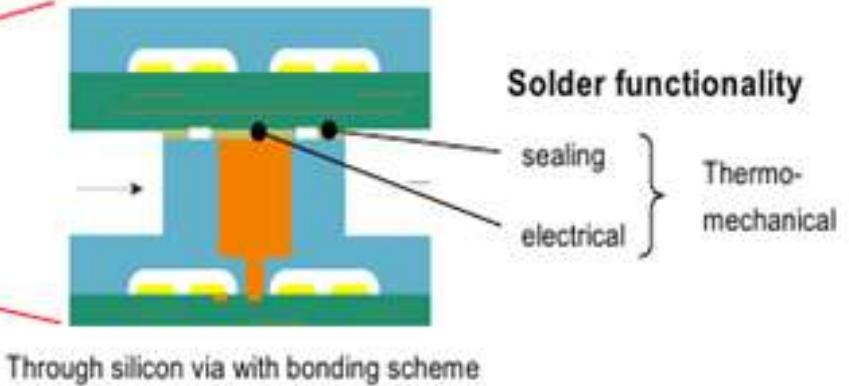
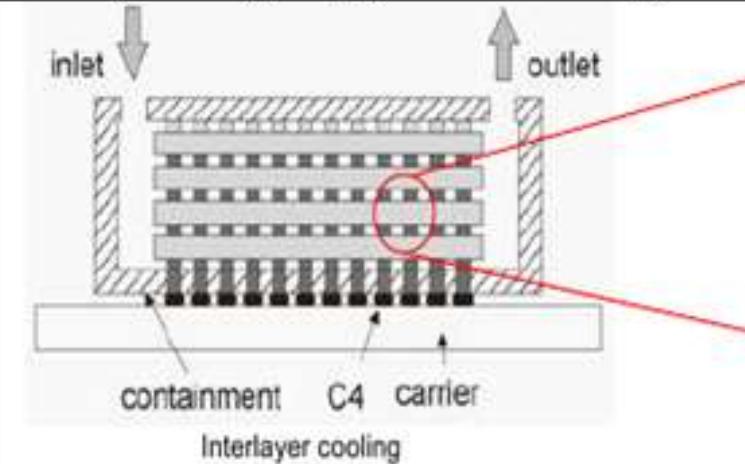
Варианты пост-Муровских технологий ЭКБ

3D сборка – IBM TSV



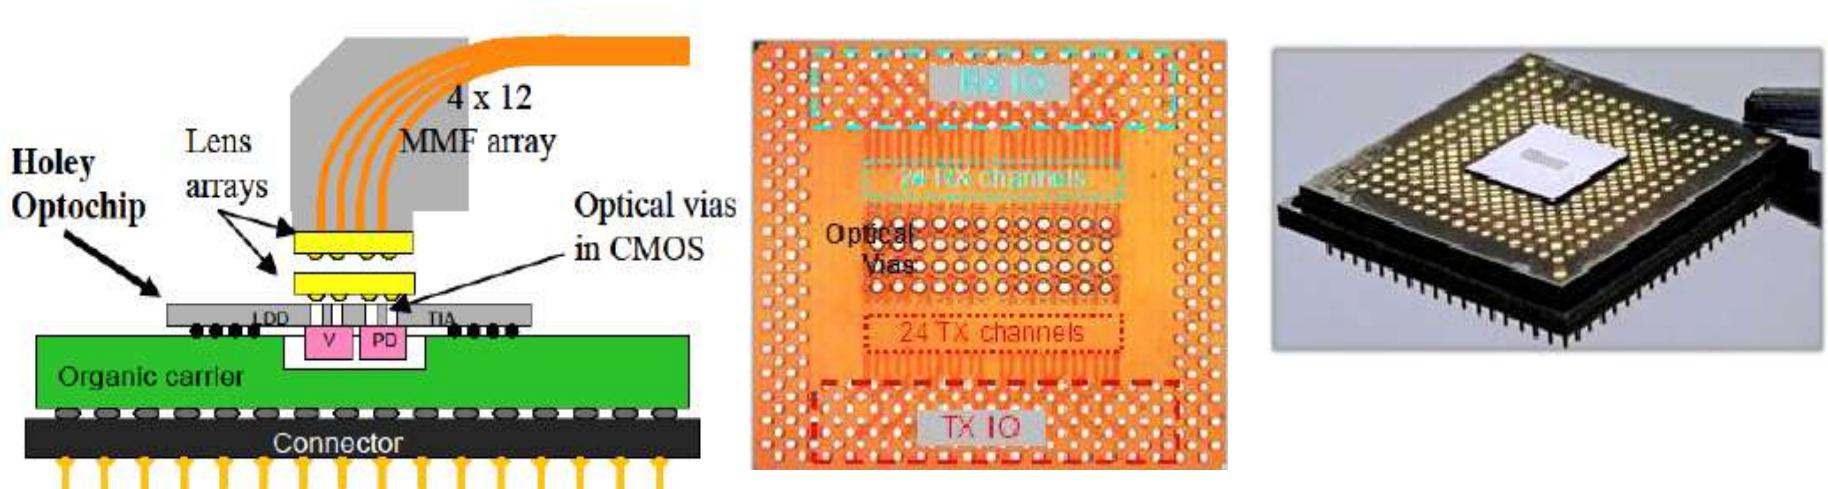
Общий вид модуля с охлаждением

Вид модуля сбоку.



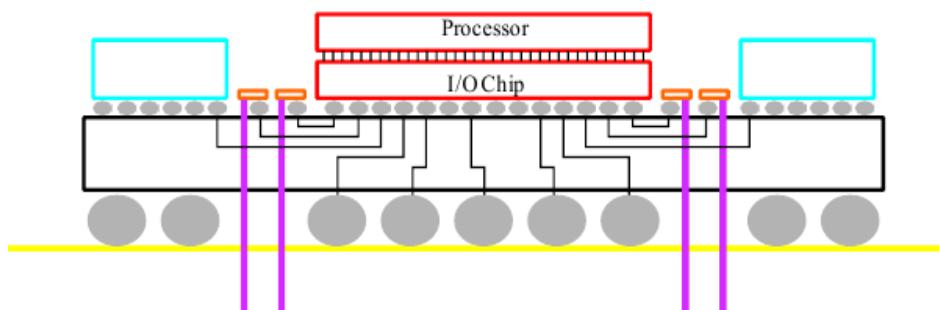
Уточненный вид сбоку с выделением соединений и изоляции.

Коммуникационный опточип IBM Holley и вариант перспективной компоновки вычислительного модуля

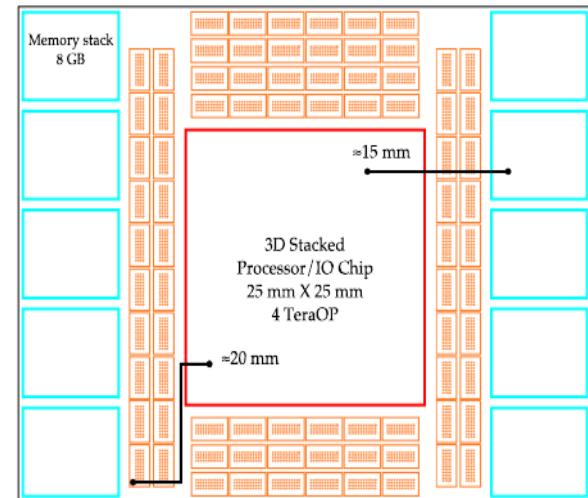


90 нм, 48 линков по 12.5 Gb/s (24(in)+24(out)), ~5x5мм, 8 pJ/bit.

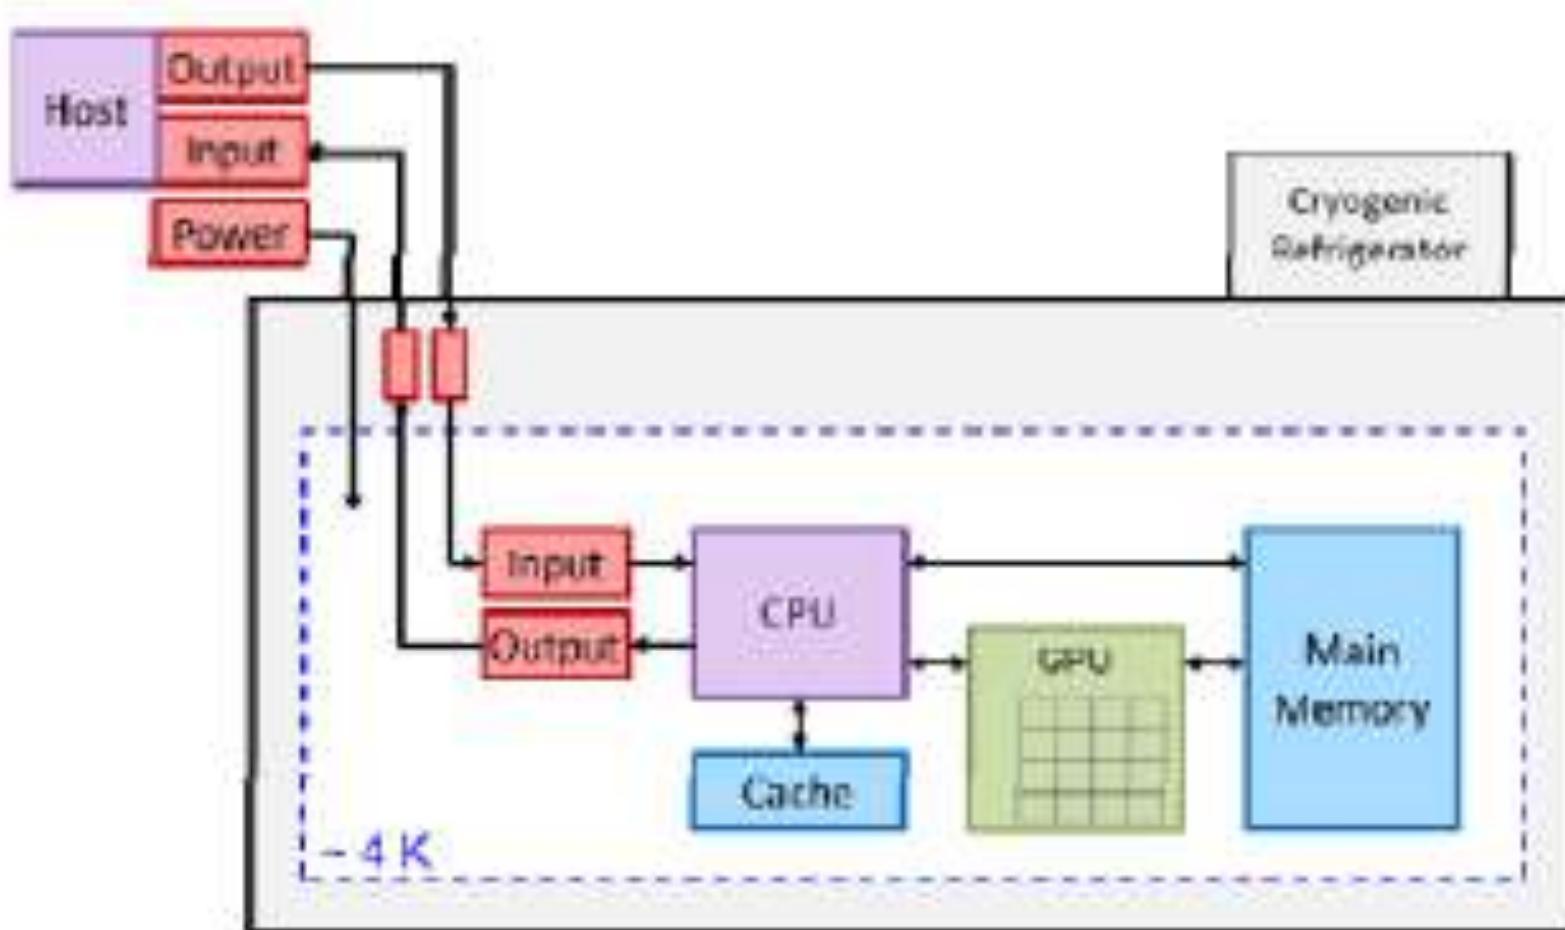
Перспектива (45 нм) – 40 Gb/s, 1 pJ/bit (0.8 – E, 0.2 – O)



Узел - 5x6 см, 82 (OE), 1968 VCSL + 1968 PD,
6 узлов в группе, 4 группы в модуле



Вычислительный узел криогенного суперкомпьютера (RSFQ), создаваемого по программе IARPA C3 (5 лет)



Характеристики модуля и компонентов

CPU

#	Parameter	Goal
1	Throughput (bit-op/s)	10^{13}
1	Efficiency @ 4 K (bit-op/J)	10^{15}
2	Main memory, total (B)	2^{27}
2	Cache memory, total (B)	2^{15}
2	Input/Output (bit/s)	10^8

Общие

GPU

#	Parameter	Goal
1	Word size (bit)	64
2	Efficiency @ 4 K (bit-op/J)	5×10^{15}
2	Processor class	ARM™ or Intel Atom™
2	Instruction set	ARM™ or simple x86
2	ALUs	1 integer
2	Throughput (bit-op/s)	10^{12}

#	Parameter	Goal
2	Efficiency @ 4 K (bit-op/J)	10^{16}
2	Instruction size (bit)	64
2	Data size (bit)	64
2	PU count	8
2	PU register size (bit)	64×128
2	PU ALUs	1 integer
2	PU throughput (bit-op/s)	2×10^{12}
3	PU area (mm²)	10

Cach

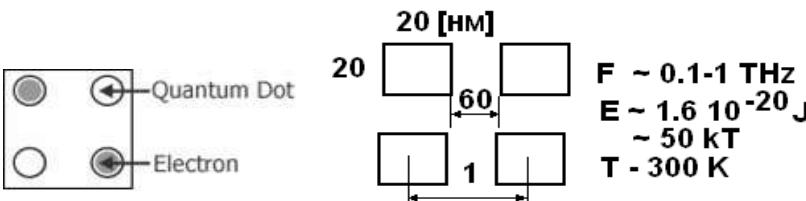
#	e	Parameter	Goal
1		Access energy @ 4 K, ave. (J/bit)	5e-18
1		Power, static (W/bit)	< 5e-19
2		Write time (ps)	200
2		Read time (ps)	100
2		Read rate, burst mode (Gbit/s)	300
2		Capacity per memory chip (bit)	$\geq 2^{16}$
2		Density (bit/cm²)	$1e+7$
3		Read/Write error rate	$1e-12$
3		Read/Write disturb rate	$1e-12$

Memory

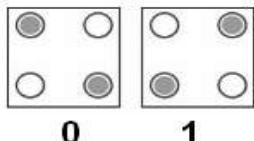
#		Parameter	Goal
1		Access energy @ 4 K, ave. (J/bit)	5e-17
1		Power, static (W/bit)	< 5e-19
2		Write time (ps)	2,000
2		Read time (ps)	500
2		Read rate, burst mode (Gbit/s)	50
2		Capacity per memory chip (bit)	$\geq 2^{26}$
2		Density (bit/cm²)	$1e+8$
3		Read/Write error rate	$1e-12$
3		Read/Write disturb rate	$1e-12$

Элементы QCA-логики

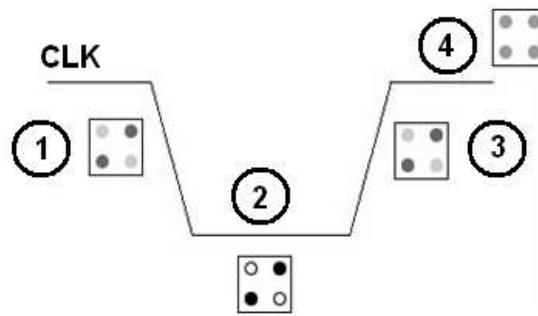
4-х точечная QCA-ячейка



QCA-ячейки в состоянии 0 и 1



Управление QCA-ячейкой

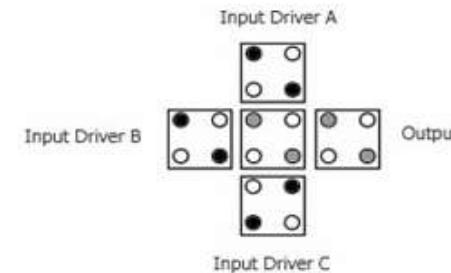


Сигнал CLK влияет на уровень туннелирования:

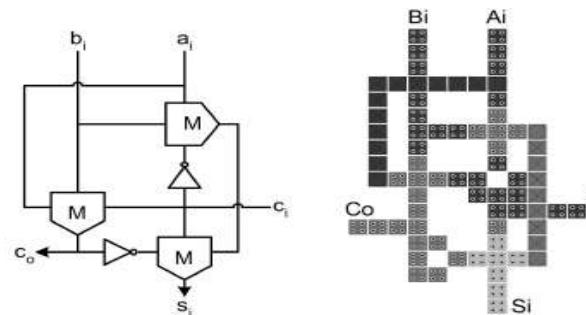
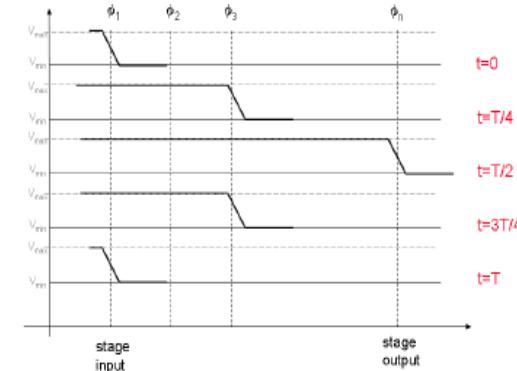
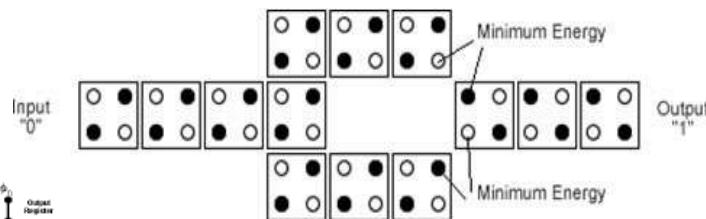
- 1 - переходное состояние (меняется уровень)
 - 2- стабильное состояние (уровень высокий)
хранение информации
 - 3 - переходное состояние (меняется уровень)
 - 4- рабочее состояние (уровень низкий)
обработка информации, логика клеточного
автомата

QCA majority gate

$$M(a,b,c) = ab + bc + ca$$

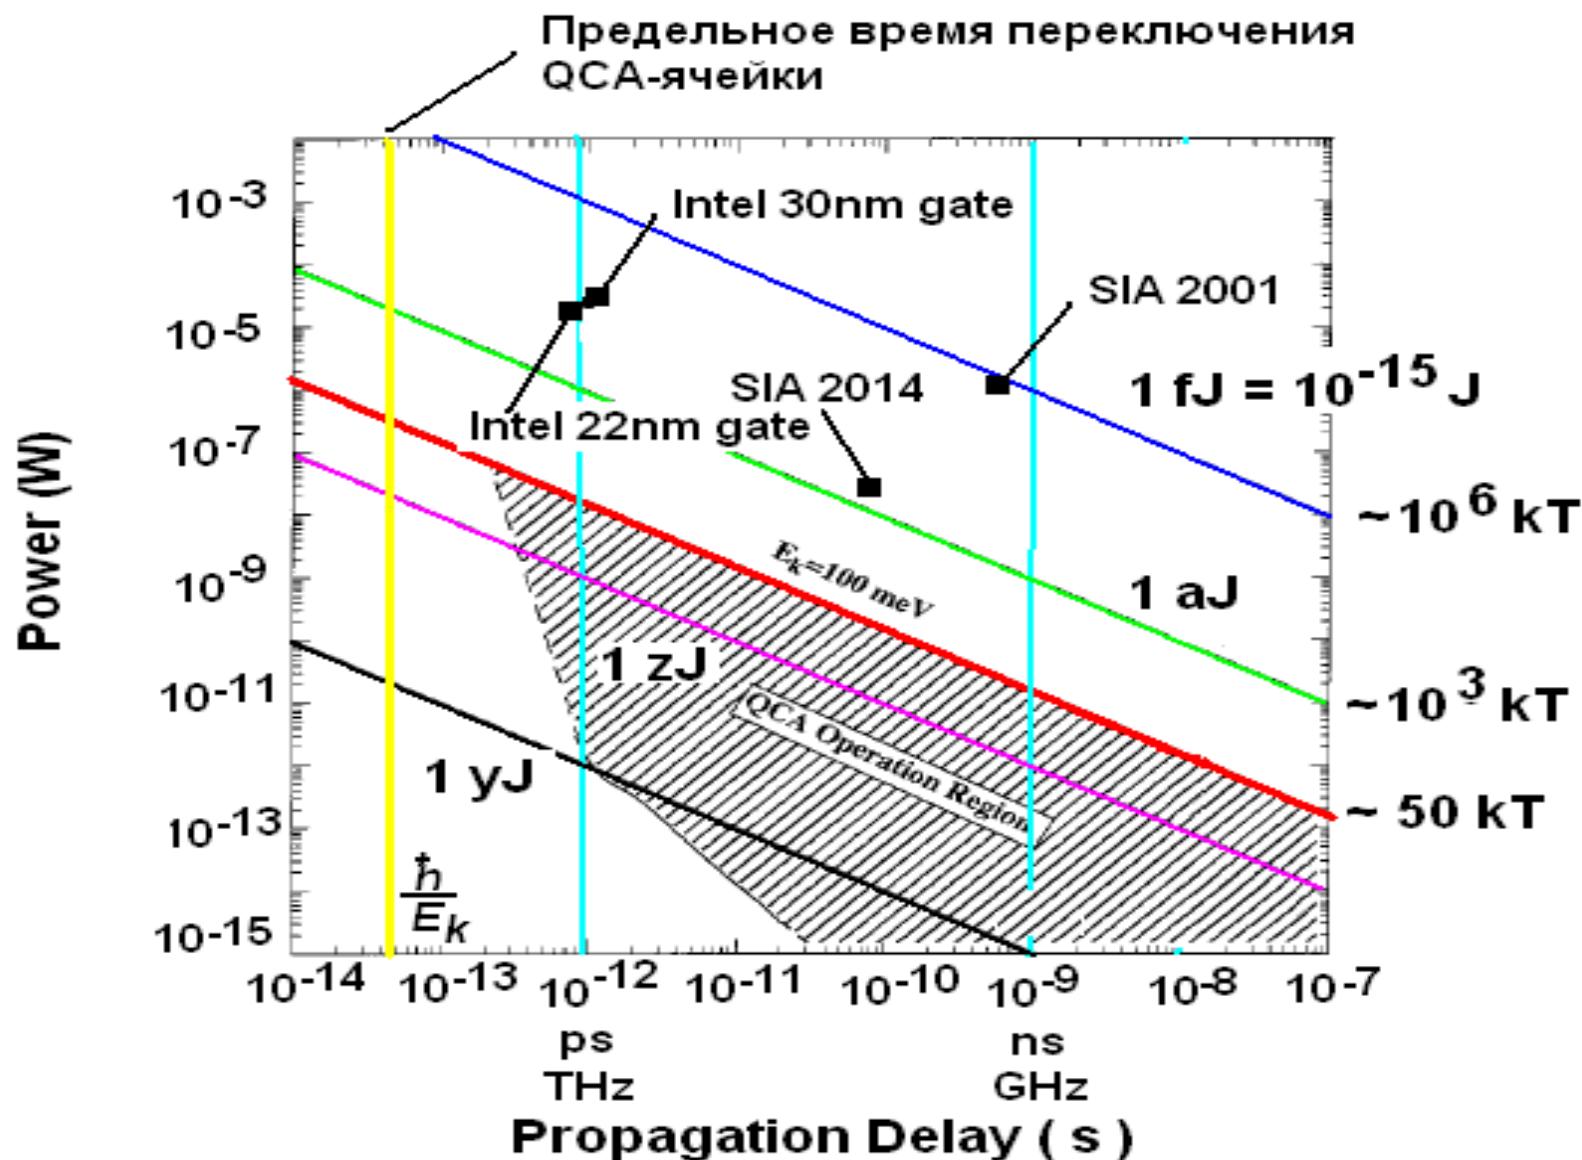


QCA inverter



Разряд сумматора

Прогноз 2006 года по перспективам создания зеттафлопсной машины на КМОП и QCA - 4



Выводы (первоочередные задачи в области инновационных СКТ)

- Разработка проблемно-ориентированных (co-design) микропроцессоров на базе перспективных архитектурных принципов
- Проведение исследований и разработок по новым моделям вычислений и организации памяти, а также эмуляции массово-мультитредовых суперкомпьютеров с глобально адресуемой памятью
- Организация работы экспертного сообщества для планирования и оценки работ, формирование нескольких десятков исследовательских групп для работы в области инновационных суперкомпьютерных технологий
- Активизация работ по сверхпроводниковой электронике и нанофотонике, для целенаправленной работы в области ЭКБ перспективных суперЭВМ (криогенная электроника, квантовая электроника)

Вопросы ?

Эйсымонт Леонид Константинович
(ФГУП"НИИ"Квант", ФГБНУ НИИ РИНКЦЭ Минобрнауки РФ
verger-lk@yandex.ru . eisymont@rdi-kvant.ru)

Горбунов Виктор Станиславович
(ФГУП"НИИ"Квант", gorbunov@rdi-kvant.ru)