

СУПЕР-ЭВМ

СЕТЕВЫЕ РЕШЕНИЯ

Комаров С.О.


КОММУНИКАЦИОННЫЕ СЕТИ СУПЕРКОМПЬЮТЕРОВ

- Коммерческие:
Infiniband
- Не коммерческие:
IBM BlueGene, Cray XT
- Российские разработки:
СКИФ-Аврора, МВС-Экспресс, Ангара

СЕМЕЙСТВО “СКИФ”

Ряд	Годы и пиковая произв-ть	ядер CPU/ разряд.	Сетевые решения	Форм-фактор CPU/U	Примечание
1	2000–2003 20–500 GFlops	1/32	FastEth, SCI (2D-top), Myrinet	4U–1U 0.5–2	Отечественный SCI (2D-top)
2	2003–2007 0.1 – 5 Tflops	1/ 32–64	GB Eth, SCI (3D-top), InfiniBand	1U, HyperBld. 2	ServNet v.1, v.2 Ускорители: FPGA, OBC
3	2007–2008 5–150 Tflops	2–4/64	GB Eth InfiniBand DDR	1U, blades 2–4	ServNet v.3 воздух—вода— фреон
4	2009–2012 ~0.5–5 Pflops	4–12/64	InfiniBand QDR, отечественная сеть (3D-top)	плотные blades 10.7	Ускорители: FPGA, GPU, МЦОС

СКИФ-АВРОРА



2 процессора


Оперативная
память

ПЛИС маршрутизатора
системной сети
«трехмерный тор»

6 трансиверов
системной сети
«трехмерный тор»


Вспомогательная сеть
InfiniBand

СКИФ-АВРОРА




СИСТЕМНАЯ СЕТЬ «3D-ТОР»

- ☆ Хорошие: пропускная способность, задержка и темп выдачи сообщений
- ☆ Перестраиваемая системная сеть
 - Коммутаторы для конфигурирования сети
 - Тор можно разбить на подтопы
 - Задаче можно назначить свой собственный подтор




СИСТЕМНАЯ СЕТЬ «3D-ТОР»


★ 1^{ое} направление (X):
16 узлов,
соединение без
кабелей, на
соединительной
панели



★ 2^{ое} направление (Y):
16 шасси, кабели
внутри стойки



★ 3^{ье} направление (Z):
кабели между
стойками,
1–32 стойки



ПРОГРАММНЫЙ СТЕК SKIF-3D-TORUS

Прикладная программа

Коммуникационные библиотеки

SKIF-MPI

SKIF-SHMEM

SKIF-ARMC1

SKIF-GASNET

ALT Linux SKIF Cluster

SKIF-Driver

**Коммуникационная библиотека
нижнего уровня**

SkifCh

Маршрутизатор системной коммуникационной сети

SKIF-3D-router (VHDL)

SKIF-3D-ROUTER (VHDL)


- Роутер реализован в FPGA
 - решены проблемы вида “deadlock”, “livelock”, “starvation”
 - виртуальные каналы и туннели
 - отказоустойчивость
- Реализованы различные алгоритмы маршрутизации и их композиции
 - Статическая маршрутизация
 - Адаптивная маршрутизация
- “SkifCh” — коммуникационная библиотека низкого уровня

TESTING

Убраны громоздкие и неэффективные схемы трансляции адресов, присутствующие в коммерческих коммуникационных сетях, таких как Infiniband.

	SKIF-3D-Torus	Infiniband QDR
Bandwidth (Gbps per node)	60	40
Message Rate (MT/s)	14	3
Latency (μ s)	1–1.5	1–1.5

КОММУНИКАЦИОННАЯ СЕТЬ “АНГАРА”



- Топология «4D-тор»
- Односторонние коммуникации:
 - put (запись в удалённую память)
 - get (чтение из удалённой памяти)
 - атомарные операции add и xor
- Коллективные операции:
 - broadcast
 - reduce
- 10 инжекционных конвейеров
- Адаптивная передача пакетов
- Механизмы синхронизации

КОММУНИКАЦИОННАЯ СЕТЬ “АНГАРА”

Характеристика	Ангара (FPGA)	Ангара (ASIC)	Infiniband FDR 4x	IBM BG/Q (Custom)	Cray XK7 (Custom)
Топология сети	2D-тор	4D-тор	Fat tree	5D-тор	3D-тор
ПС с процессором, Гбайт/с	2	8	6,4	~ 20	9,6
ПС линка, Гбайт/с	0,78	7,5	6,8	2	9,375
Агрегатная ПС линков, Гбайт/с	6,3	120	-	40	186
Задержка между соседними узлами, мкс	2,1	1.0	1,0	< 1,0	1,4
Стоимость, т. руб./узел	≈120	≈38	≈41	-	-

КОММУНИКАЦИОННАЯ СЕТЬ “АНГАРА”

Характеристики EC8430:

Техпроцесс.....	TSMC 65nm GP
Размер.....	13.0mm x 10.5mm
Кол-во транзисторов.....	180M
Частота.....	500MHz
TDP.....	36W
Интерфейсы:	
GEN II PCI-E.....	x16 (5.0Gbps/lane, 80 Gbps total each way)
Links.....	x8 (1-12 lanes/link 3.125-6.25 Gbps/lane, max. 75 Gbps/link each way, total max. 600 Gbps each way)
DDR3 SDRAM.....	Peak BW 8.5 Gbyte/s (72 bit, 1066 MT/s)
Электропитание:	
SerDes	1.0V±5%
Core.....	1.0V±5%
I/O.....	2.5V±10%
Темп. диапазон.....	0-70°C
Корпус.....	FCBGA-1521 40mm x 40mm




ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ “АНГАРА”



- Поддержка прикладных (математических, алгоритмических) библиотек (BLAS, LAPACK, FFTW, GSL, MKL и т.д.).
- Поддержка компиляторов языков Fortran 77/90/95 (GNU, Intel), C/C++ (GNU, Intel), UPC, Co-Array Fortran.

КОММУНИКАЦИОННАЯ СЕТЬ НА БАЗЕ «МВС-ЭКСПРЕСС»

- Коммутатор
- Интерфейсные платы (ИП), подключенные к магистралям PCI Express вычислительных модулей (ВМ)
- Сетевых кабелей (СП)



ОСОБЕННОСТИ «МВС-ЭКСПРЕСС»

- Использование PCI Express для передачи данных как внутри узла, так и между
 - должен быть выделен один VM, называемый «ведущим», в отличие от остальных - «ведомых», для размещения в его адресном пространстве окон доступа ко всем ведомым узлам
 - в каждом VM, как правило, должен быть выделен тред или ядро (в многоядерных VM), предназначенные для работы с интерфейсной платой, для поддержки синхронизации и когерентного состояния памяти VM.

ПРОГРАММНЫЙ СТЕК «МВС-ЭКСПРЕСС»

Прикладная программа

Коммуникационные библиотеки

SKIF-MPI

SKIF-SHMEM

SKIF-ARMC1

SKIF-GASNET

Linux

MVS-Express-Driver


**Коммуникационная библиотека
нижнего уровня**

SkifCh-MVS-Express

Маршрутизатор системной коммуникационной сети

МВС-Экспресс

TESTING




BLUE GENE

- IBM Blue Gene Projects:
 - **Blue Gene / L (280 TFLOPS)**
 - **Blue Gene / C**
 - **Blue Gene / P (1 PFLOP)**
 - **Blue Gene / Q (3-10 PFLOPS)**

BLUE GENE / P

- 3D Top
 - сеть общего назначения, объединяющие все вычислительные узлы (p2p)
 - пропускная способность — 425 MB/s
 - латентность (ближайший сосед):
 - 32-байтный пакет: 0,1 μ s
 - 256-байтный пакет: 0,8 μ s
- глобальные коллективные данные
 - коммуникации типа «один-ко-многим» (broadcast/редукция)
 - пропускная способность — 850 MB/s
 - латентность (полный обход): 3,0 μ s
 - операции барьеров и прерываний (глобальные AND- и OR-операции)

BLUE GENE / Q



BLUE GENE / Q

- 5D Top — 40 GB/s
- Латентность 2.5 мкс
- Broadcast/Reduce – часть 5D Top
- PCIe x8 Gen2 based I/O
- 1 GB Control Network — System Boot, Debug, Monitoring