



Спецкурс «Суперкомпьютерные вычисления»

Эффективное параллельное программирование с учетом особенностей IBM Blue Gene/P


Федулова И.А.
инженер-программист, к.ф.-м.н.
IBM Russian Systems and Technology Laboratory
irina@ru.ibm.com


01.03.2010


План лекции

- Особенности архитектуры
 - Режимы использования ядер процессоров
 - Коммуникационные сети
 - Размещение задач по процессорам (mapping)
- Blue Gene/P на ВМК
 - Логин
 - Файловая система
 - Компиляция программ
 - Запуск задач
 - Отладка
- Эффективное параллельное программирование
 - Общие рекомендации
 - Создание физически прямоугольных коммуникаторов
 - Коллективные операции
 - Использование библиотек
 - Альтернативы MPI
- Оптимизация
 - Измерение производительности
- Дополнительный материал *

Blue Gene/P System view









Характеристики вычислительного узла

- 4 ядерный 32-битный процессор PowerPC 850 МГц
 - Двойное устройство для работы с числами с плавающей запятой двойной точности
 - 2 Гб памяти
 - Работает под управлением облегченной ОС
 - Создание процессов и управление ими
 - Управление памятью
 - Отладка процессов
 - Ввод-вывод
 - Объем виртуальной памяти равен объему физической
 - 3 режима использования ядер
 - SMP: 1 MPI процесс из 4 SMP нитей, 2 Гб памяти
 - DUAL: 2 MPI процесса по 2 SMP нити, 1 Гб памяти на MPI процесс
 - VNM: 4 MPI процесс


SMP Mode
1 Process
1-4 Threads/Process




Dual Mode
2 Processes
1-2 Threads/Process



Quad Mode (VNM)
4 Processes
1 Thread/Process






Система памяти

Cache	Total per node	Size	Replacement policy	Associativity
L1 instruction	4	32 KB	Round-Robin	▶ 64-way set-associative ▶ 16 sets ▶ 32-byte line size
L1 data	4	32 KB	Round-Robin	▶ 64-way set-associative ▶ 16 sets ▶ 32-byte line size
L2 prefetch	4	14 x 256 bytes	Round-Robin	▶ Fully associative (15-way) ▶ 128-byte line size
L3	2	2 x 4 MB	Least recently used	▶ 8-way associative ▶ 2 bank interleaved ▶ 128-byte line size
Double data RAM (DDR)	2	▶ Minimum 2 x 512 MB ▶ Maximum 4 GB	N/A	▶ 128-byte line size

Double Hammer FPU




- SIMD инструкции могут выполняться одновременно на двух FPU
- Параллельные операции load/store
- Данные **должны** быть выровнены по 16-байтовой границе
 - Иначе производительность будет **значительно снижена**
 - Даже хуже, чем при использовании только одного FPU
- Компилятор сможет сгенерировать SIMD инструкции, только если данные в памяти расположены подряд (stride-one access)
 - Хотя при более высоких (-O4, -O5) уровнях оптимизации компилятор попытается сгенерировать SIMD инструкции и для данных, расположенных не подряд
 - -O3 -qarch=450d -qtune=450

Узлы ввода-вывода


- Используются для связи вычислительных узлов с файловой системой
- В целом точно такие же, как и вычислительные узлы, но есть отличия:
 - Установлена полноценная ОС
 - Отсутствует подключение к сети-тору
 - Имеется подключение к 10 Гб сети Ethernet

Коммуникационные сети




3-мерный тор

- Виртуальная аппаратная маршрутизация без буферизации
- 3.4 Гбит/с на всех 12 портах (5.1 ГБ/с на узле)
- Аппаратные задержки: 0.5 мс между соседними узлами, 5 мс между самыми далекими
- Задержки MPI: 3мс между соседними узлами, 10 мс между самыми далекими
- **Основная коммуникационная сеть**
- **Используется в том числе для многих коллективных операций**



Коллективная сеть – дерево

- Для глобальной коммуникации один-ко-всем (broadcast, reduction)
- 6.8 ГБ/с на порт
- Задержка на один проход дерева: аппаратная 1.3 мс, MPI 5 мс
- Соединяет все вычислительные узлы и узлы ввода-вывода
- **Используется для коллективных операций и коммутатора MPI_COMM_WORLD**





Высокоскоростная сеть для глобальных прерываний

- Задержка на оповещение всех узлов: аппаратная 0.65 мс, MPI 5 мс
- **Для MPI_Barrier**

Размещение процессов MPI по узлам (mapping)

- Латентность зависит от расстояния, на которое передаются сообщения
- Hop distance — количество промежуточных узлов
 - Расстояние Манхеттена



Размещение процессов MPI по узлам (mapping)

- Доступные размеры физических решеток

- 32: 4 x 4 x 2
- 64: 4 x 4 x 4
- 128: 4 x 4 x 8
- 256: 8 x 4 x 8
- 512: 8 x 8 x 8
- 1024: 8 x 8 x 16
- 1024: 8 x 16 x 8
- 2048: 8 x 16 x 16


- Чтобы указать конкретную размерность решетки для 1024 узлов, в командном файле необходимо указать параметры

```
bg_rotate=false  
bg_shape=8x8x16 либо bg_shape=8x16x8
```


Матрица расстояний между узлами

- Зависит от
 - размера раздела
 - способа нумерации узлов
- Не зависит от программы
- Как получить матрицу расстояний?
 - Написать простую программу, которая ее рассчитывает


Примеры матриц расстояния между узлами




$N_p = 128$



$N_p = 256$



$N_p = 512$ (MESH)



$N_p = 512$ (TORUS)

Матрица коммуникации MPI программы

- Зависит от программы и ее входных параметров
- Не зависит от того, на каком (супер)компьютере программа запущена

- Как получить матрицу коммуникации?

- Использовать HPC Toolkit

Указать при линковке

```
-lmpitrace -L<путь к библиотеке>
```

При запуске указать переменные окружения


```
-e TRACE_SEND_PATTERN=yes -e TRACE_ALL_EVENTS=yes
```

Запустить программу


Получить файл `send_bytes.matrix`

- Содержит квадратную матрицу `Nproc x Nproc` чисел типа `double`
 - (i, j) элемент матрицы = количество байт, переданных от процессора i процессору j
 - Самостоятельно инструментировать `MPI_Send/MPI_Recv`


Примеры матриц коммуникации




PBLAS: 128 nodes, SMP




PBLAS: 128 nodes, DUAL




FAT_SGEMM, $blk = 8$, 128 nodes, VN



FAT_SGEMM, $blk = 64$, 128 nodes, VN





Размещение процессов MPI по узлам (mapping)

■ Выводы

- Необходимо учитывать то, как будет отображаться коммуникационная матрица на топологию на этапе написания программы
- Можно экспериментировать со стандартными мэппингами
- Можно создавать mapping-файлы вручную

IBM Blue Gene/P на ВМК

- 2 стойки по 1024 4-ядерных процессора
 - Общий объем ОЗУ: 4Тб
 - Пиковая производительность: 27.2 Тфлоп/с
 - Реальная производительность по тесту Linpack: 23.2 Тфлоп/с
 - 85% от пиковой



IBM Blue Gene/P на ВМК

■ Доступ к системе ограничен

- Внутри факультета ВМК с любого IP адреса
- Извне — только с отдельных IP адресов (индивидуально для пользователей)
- При первом логине необходимо сменить пароль

```
$> ssh username@bluegene1.cs.msu.su  
$> passwd
```

■ Файловая система

- `/home/username`
 - постоянное хранение файлов
 - редактирование текстов программ
 - компиляция
 - обработка результатов и визуализация
- `/gpfs/data/username`
 - временное хранение (только на время запуска и выполнения программы)
 - перед запуском программы необходимо переписать исполняемый файл и входные файлы на `/gpfs`
 - после окончания счета необходимо переместить результаты в `/home`

Компиляция программ

Компилятор		C/C++		Fortran			
		C	C++	Fortran 77	Fortran 90	Fortran 95	Fortran 2003
GCC		<code>mpicc</code>	<code>mpicxx</code>	<code>mpif77</code>	—	—	—
IBM XL		<code>mpixlc</code>	<code>mpixlcxx</code>	<code>mpixlf77</code>	<code>mpixlf90</code>	<code>mpixlf95</code>	<code>mpixlf2003</code>
	ПОТОКО- безопасная версия	<code>mpixlc_r</code>	<code>mpixlcxx_r</code>	<code>mpixlf77_r</code>	<code>mpixlf90_r</code>	<code>mpixlf95_r</code>	<code>mpixlf2003_r</code>

Компиляция программ

```
irina@fen1:~/gpfs/helloworld> cat hello.cpp
```

```
#include <mpi.h>
#include <iostream>
```

```
int main (int argc, char *argv[])
{
    MPI_Init (&argc, &argv);

    int sz, id;
    MPI_Comm_size (MPI_COMM_WORLD, &sz);
    MPI_Comm_rank (MPI_COMM_WORLD, &id);

    std::cout << "hi! i'm " << id << " of " << sz << std::endl;

    MPI_Finalize();
}
```

```
irina@fen1:~/gpfs/helloworld> mpicxx hello.cpp -o hello
```

```
irina@fen1:~/gpfs/helloworld> ls -l hello
```

```
-rwxr-xr-x 1 irina cmc 14550266 2009-11-02 12:07 hello
```

Ключи компилятора

- `-qarch=450 -qtune=450`
 - Инструкции только для одного из двух FPU
 - Используйте, если данные не выровнены по 16-байтовой границе
- `-qarch=450d -qtune=450`
 - Выравнивание!
- `-O3 (-qstrict)`
 - Минимальный уровень оптимизации под Double Hammer FPU
- `-O3 -qhot (= -qsimd)`
- `-O4 (-qnoipa)`
- `-O5`
- `-qdebug=diagnostic`
 - Информация по SIMD-инструкциям (только с `qhot`)
- `-qreport -qlist -qsource`
 - Много полезной информации в `.lst` файле

Постановка заданий в очередь

- Система управления заданиями IBM LoadLeveler
 - Оптимизирует использование имеющихся вычислительных ресурсов
 - Учет приоритета задач и пользователей
 - Динамическое распределение ресурсов
 - Очередь заданий
- Основные команды для системы LoadLeveler
 - **llsubmit** — постановка задачи в очередь

```
irina@fen1:~/gpfs/helloworld> llsubmit test.jcf
llsubmit: The job "fen1.bg.cmc.msu.ru.42037" has been submitted.
```

- **llq** — просмотр текущего статуса очереди

```
irina@fen1:~/gpfs/helloworld> llq
```

Id	Owner	Submitted	ST	PRI	Class	Running On
fen1.42037.0	irina	11/1 20:56	R	50	n128_m15	fen1
fen1.42024.0	kovalev	11/1 21:21	R	50	n512_h12	fen1
fen1.42016.0	ruby_rush	11/1 13:45	I	50	n2048_m03	
fen1.42025.0	psmart	11/1 21:21	NQ	50	n1024_h24	

Удаление задач из очереди

- **llcancel** — удаление задач из очереди, если задача еще не запущена на счет (статус I, NQ, P)

```
irina@fen1:~/gpfs/helloworld> llcancel 42037  
llcancel: Cancel command has been sent to the central manager.
```

- **Важное замечание: у Blue Gene/P на ВМК есть особенность**
 - если задача уже запущена (статус R),
... лучше ее **не удалять**, иначе может возникнуть проблема с запуском последующих задач
 - есть надежда, что эта проблема скоро будет решена администраторами

Скрипт mpisubmit.bg

- Составляет командный файл для LoadLeveler-a
- Ставит задачу в очередь

```
irina@fen1:/gpfs/data/irina/helloworld> mpisubmit.bg -n 128 -w 00:15:00 \
                                          -e OMP_NUM_THREADS=4 \
                                          -m smp hello -- arg1 arg2
```

-n, --nproc	128	Запрашиваемое число узлов
-w, --wtime	00:15:00	Максимальное время выполнения
-m, --mode	smp	Режим использования ядер процессора
-e, --env		Переменные окружения
-t, --top	PREFER_TORUS	Топология
-d, --debug		Вывести содержимое командного файла на экран без постановки задачи в очередь
-h, --help		

Командный файл изнутри

- Структура файла
 - комментарии начинаются с #
 - команды LoadLeveler-а начинаются с #@
- Файл содержит
 - название исполняемого файла
 - класс задачи (наименование очереди)
 - требуемые ресурсы (число узлов, время выполнения)
 - имена входных и выходных файлов

```

#@ job_type = bluegene
#@ bg_size = 128                # количество запрашиваемых узлов
#@ wall_clock_limit = 00:15:00  # требуемое время
#@ class = n128_m15             # класс задачи
#@ bg_connection = PREFER_TORUS
#@ output = hello.%(jobid).out  # файл стандартного вывода
#@ error = hello.%(jobid).err   # файл потока ошибок
#@ notification = never
#@ queue
/bgsys/drivers/ppcfloor/bin/mpirun \
    -env CMC_SITE_SPECIFIC=n128_m15 \
    -np 128 \
    -mode smp \                  # режим использования ядер на процессоре
    -exe hello \                # относительный путь, но тогда llsbmit из каталога на gpfs
    -verbose 2                  ... либо абсолютный путь

```

Параметр mapping

- Стандартные мэппинги можно задать параметром для скрипта `mpisubmit.bg`
 - `--e BG_MAPPING=TXYZ`
- Любой мэппинг можно указать в командном файле как параметр `mpirun`
 - `--mapfile /gpfs/data/irina/hello/mapfile.txt`

```
#@ job_type = bluegene
#@ class = large
#@ wall_clock_limit = 02:00:00
#@ error = cpmd.$(jobid).err
#@ output = cpmd.$(jobid).out
#@ bg_size = 512
#@ bg_connection = PREFER_TORUS
#@ queue
/bgsys/drivers/ppcfloor/bin/mpirun \
    -exe /gpfs/data/irina/bin/cpmd.smp+mpi.x \
    -args "lneutral.inp" \
    -env "PP_LIBRARY_PATH=/gpfs/data/irina/cpmd/pp_library/ BG_MAPPING=TXYZ OMP_NUM_THREADS=4" \
    -mapfile randomMapping_n512.txt \
    -mode smp -verbose 2
```

5	2	6	0
1	5	0	0
6	7	4	0
2	3	7	0
1	2	0	0
4	3	3	0
7	7	7	0
0	2	1	0
5	4	3	0
4	2	1	0
5	6	3	0
5	5	2	0
4	7	7	0

Отладка

- На Blue Gene нет виртуальной памяти, поэтому необходимо тщательно следить за утечками памяти
- Ключ компилятора -g
- addr2line
 - Утилита для анализа core файлов
- Application killed with signal 6
 - Недостаточно памяти
- Application killed with signal 7 (memory alignment error)
 - BG_MAXALIGNEXP=1
 - процесс умирает при первой ошибке выравнивания (полезно при оптимизации)
 - BG_MAXALIGNEXP=-1
 - игнорировать ошибки выравнивания

Общие рекомендации по написанию MPI программ

- Стремитесь выполнять коммуникации и вычисления одновременно
- Избегайте несбалансированной нагрузки
- Избегайте буферизации при отправке сообщения
 - Recv заранее
- Избегайте использования специальных типов данных
 - перед отправкой система их будет упаковывать, тратя на это время
- Специфичные для Blue Gene рекомендации:
 - Используйте прямоугольные коммутаторы
 - Используйте коллективные операции вместо большого числа операций точка-точка
 - Следите за выравниванием данных на 16-байтовую границу

Прямоугольный коммуникатор

```
#include <mpix.h>
int MPIX_Cart_comm_create(MPI_Comm *cart_comm);
```

- Создает четырехмерный декартов коммуникатор, логические размерности которого совпадают с физическими размерами аппаратного раздела (partition)
- Координаты в логическом коммуникаторе и физическом partition совпадают
- Коллективная операция

Характеристики коллективных операций

- Для Blue Gene была разработана специальная реализация MPICH2
- Оптимизированы коллективные операции
- Производительность коллективных операций зависит от
 - Коммуникатора
 - Типа данных
- Таблица полностью есть в Redbook-e

MPI routine	Communicator	Data type	Network	Latency	Bandwidth
MPI_Barrier	MPI_COMM_WORLD	N/A	Global Interrupts	1.25 μ s	N/A
	Rectangular	N/A	Torus	10.96 μ s	N/A
	All other subcommunicators	N/A	Torus	22.61 μ s	N/A
MPI_Bcast	MPI_COMM_WORLD	Byte	Collective for latency, torus for BW	3.61 μ s	2047 MBps ^a
	Rectangular	Byte	Torus	11.58 μ s	2047 MBps ^a
	All other subcommunicators	Byte	Torus	15.36 μ s	357 MBps
MPI_Allreduce	MPI_COMM_WORLD	Integer	Collective for latency, torus for BW	3.76 μ s	780 MBps ^a
		Double	Collective for latency, torus for BW	5.51 μ s	363 MBps ^a
	Rectangular	Integer	Torus	17.66 μ s	261 MBps ^a
		Double	Torus	17.54 μ s	363 MBps ^a
	All other subcommunicators	Integer	Torus	38.06 μ s	46 MBps

Использование оптимизированных библиотек

■ ESSL

- линейная алгебра
 - матричные операции
 - задачи на собственные значения
 - преобразование Фурье
 - сортировка и поиск
 - интерполяция
 - генерация случайных чисел
-
- не параллельная! Использует OpenMP, может работать только в рамках одного узла
 - Используйте ScaLAPACK вместо Parallel ESSL


```
-lesslbg -L/bgsys/ibm_essl/sles10/prod/opt/ibmmath/lib  
-lesslsmpbg
```

■ MASS

- sin, cos, tan, sqrt, rsqrt, exp, log, ...
- IBM XL компилятор линкует MASS автоматически

Альтернативы MPI

- DCMF
- Надстройки над DCMF
 - MPICH2
 - Global Arrays
 - Charm++
 - Berkeley UPC
 - ARMCI: Aggregate Remote Memory Copy Interface



Измерение производительности

■ Производительность на уровне MPI

- HPC Toolkit: libmpitrace
- TAU: <http://www.cs.uoregon.edu/research/tau/>
- mpiP: <http://mpip.sourceforge.net/>
- Jumpshot:
<http://www.mcs.anl.gov/research/projects/perfvis/software/viewers/>
- ...

■ Производительность на уровне процессора

- HPC Toolkit: Xprofiler, libhpm
- PAPI: <http://www.redbooks.ibm.com/abstracts/redp4256.html>
- UPC wrappers: <http://hpc.cs.msu.su/en/bgp/development/performance>
- gprof

Измерение производительности вручную

<http://www.fz-juelich.de/jsc/jugene/usage/FAQ/measurement>

```
#include <sys/resource.h>
#include <common/bgp_personality.h>
#include <common/bgp_personality_inlines.h>
#include <spi/kernel_interface.h>

static _BGP_Personality_t mybgp;

/* returns memory per core in MBytes */
unsigned bg_coreMB() {
    unsigned procMB, coreMB;
    Kernel_GetPersonality(&mybgp, sizeof(_BGP_Personality_t));
    procMB = BGP_Personality_DDRSizeMB(&mybgp);
    coreMB = procMB/Kernel_ProcessCount();
    return coreMB;
}

/* return maximum memory usage of process in kBytes */
unsigned bg_usedKB() {
    struct rusage usage;
    if (getrusage(RUSAGE_SELF, &usage) != 0) return 0;
    return usage.ru_maxrss;
}

#include <common/bgp_personality.h>
#include <common/bgp_personality_inlines.h>
#include <spi/kernel_interface.h>
static _BGP_Personality_t mybgp;
static double clockspeed=0.0;

/* initialize the clockspeed scaling factor */
unsigned bg_wtime_init() {
    unsigned clockMHz;
    Kernel_GetPersonality(&mybgp, sizeof(_BGP_Personality_t));
    clockMHz = BGP_Personality_clockMHz(&mybgp);
    clockspeed = 1.0e-6/(double)clockMHz;
    return clockMHz;
}

/* return time in seconds */
double bg_wtime() {
    return ( _bgp_GetTimeBase() * clockspeed );
}
```


Источники информации

- Сайт «Высокопроизводительные вычисления на ВМК МГУ»

<http://hpc.cs.msu.su/>

- **Redbook** IBM System Blue Gene Solution: Blue Gene/P Application Development

<http://www.redbooks.ibm.com/abstracts/sg247287.html>

- Материалы прошлогодного спецкурса «Терафлопные вычисления»

<http://angel.cmc.msu.ru/~ifed/teraflops/>

- Сайт Blue Gene/P в суперкомпьютерном центре Юлиха (Германия)

<http://www.fz-juelich.de/jsc/jugene/usage/>

- Тонкая настройка ключей компилятора

http://www.nccs.gov/wp-content/training/2008_bluegene/ORNLCmpOptimization.pdf

- Сайт центра научных вычислений бостонского университета

<http://scv.bu.edu/computation/bluegene/>

Дополнительный материал *

Тонкая настройка MPI

- Все операции точка-точка и коллективные операции на субкоммуникаторах выполняются через тор
- Детерминированная маршрутизация
 - Может привести к образованию «горячих точек»
- Адаптивная маршрутизация
 - Дополнительные накладные расходы
- Маршрутизация зависит от размера сообщения
 - short protocol: 1 пакет < 244 байт: детерминированная
 - eager protocol: сообщения «средних» размеров (по умолчанию < 1200 байт): детерминированная
 - rendezvous protocol: после предварительного установления контакта используется DMA (Direct Memory Access) с адаптивной маршрутизацией
 - Максимальная эффективность по bandwidth, но и максимальная latency
 - переменная окружения DCMF_EAGER регулирует порог между eager и rendezvous
 - Уменьшайте DCMF_EAGER, если используете много коротких сообщений и далекие расстояния
 - Увеличивайте DCMF_EAGER, если коммуникации в основном между соседями, либо если используете довольно большие сообщения

Тонкая настройка MPI

■ Настройка MPI с использованием переменных окружения

- `mpisubmit -n 128 -env "DCMF_EAGER=2000" myprog`

■ Тонкая настройка MPI во время выполнения программы

- В последнем драйвере Blue Gene V1R3M0 появилась возможность менять значения параметров настройки MPI программно

```
int MPIX_Get_properties(MPI_Comm comm, int *prop_array);  
int MPIX_Get_property(MPI_Comm comm, int prop, int *result);  
int MPIX_Set_property(MPI_Comm comm, int prop, int value);
```

```
int main(int argc, char **argv)  
{  
    ...  
    MPIX_Get_property(comm, DCMF_USE_TORUS_ALLTOALL, &result);  
    if (result == 0)  
        /* this causes the following MPI_Alltoall to use torus protocol */  
        MPIX_Set_property(comm, DCMF_USE_TORUS_ALLTOALL, 1);  
  
    MPIX_Get_property(comm, DCMF_USE_MPICH_ALLTOALL, &result);  
    if (result == 1)  
        /* turn off the mpich protocol */  
        MPIX_Set_property(comm, DCMF_USE_MPICH_ALLTOALL, 0);  
  
    MPI_Alltoall(...);  
    /* this resets the MP_Alltoall algorithm selection to its previous state */  
    MPIX_Set_property(comm, DCMF_USE_TORUS_ALLTOALL, 0);  
    ...  
    ...  
}
```

Тонкая настройка MPI

- Параметры MPI, с которыми можно экспериментировать
 - DCMF_SENDER_SIDE_MATCHING {[0], 1}
 - DCMF_COLLECTIVE {0, [1], NOTREE}
 - Параметры, указывающие конкретный алгоритм для коллективных операций
 - DCMF_BCAST, DCMF_ALLTOALL, DCMF_ALLGATHER, DCMF_ALLREDUCE, DCMF_BARRIER, ... {MPICH, TREE, BINOM, DPUT, RECT, ...}
 - Система выбирает конкретный алгоритм в зависимости от коммуникатора
 - Полный список в Redbook
- STAR-MPI: Self-Tuned Adaptive Routines for MPI
 - Динамически выбирает оптимальный алгоритм для коллективных операций
 - Не нужно пересобирать программу, достаточно запустить с переменными окружения
 - DCMF_STAR=1 DCMF_STAR_VERBOSE=1
 - DCMF_STAR_THRESHOLD [=2048]: размер сообщения, начиная с которого будут использоваться функции STAR-MPI
 - DCMF_STAR_NUM_INVOCS=[10]: число вызовов коллективной операции, которое STAR-MPI использует для сбора статистики

Тонкая настройка MPI

■ FastMPI

- Используйте компиляторы из `/bgsys/drivers/ppcfloor/comm/fast/bin`
- Только для отлаженных кодов
- Коллективные операции не оптимизированы – ?

```
irina@fen1:~> ls /bgsys/drivers/ppcfloor/comm/fast/bin/mpi
mpicc      mpicxx      mpif90      mpixlc_r      mpixlcxx_r
  mpixlf2003_r  mpixlf77_r    mpixlf90_r    mpixlf95_r
mpich2version  mpif77      mpixlc      mpixlcxx      mpixlf2003
  mpixlf77      mpixlf90      mpixlf95
```

Compiler-friendly программирование

- Располагайте данные в непрерывных областях памяти
- Проверяйте выравнивание на 16-байтовую границу
 - `__alignx` не выравнивает и не проверяет на выравнивание, а сообщает компилятору, что массивы выровнены
- Группируйте операции с плавающей запятой
- Избегайте ветвлений внутри циклов
- Используйте `inline` функции
 - `-O5` и `-qipa` делает это автоматически
- Избегайте `aliasing`
 - Один и тот же массив передается в функцию под разными именами
 - `#pragma disjoint`

```
#include <math.h>
#include <builtins.h>
__inline void aligned_ten_reciprocal_roots (double* x, double* f)
{
  #pragma disjoint (*x, *f)
  int i;
  __alignx (16, x);
  __alignx (16, f);
  for (i=0; i < 10; i++)
    f[i] = 1.0 / sqrt (x[i]);
}
```

```
extern
#ifdef __cplusplus
"builtin"
#endif
void __alignx (int n, const void *addr)
```

```
void reciprocal_roots (double *x, double *f, int n)
{
  /* are both x & f 16 byte aligned? */
  if ( (((int) x) | ((int) f)) & 0xf) == 0) /* This could also be done as:
                                             if (((int) x % 16 == 0) && ((int) f % 16) == 0) */
    aligned_ten_reciprocal_roots (x, f, n);
  else
    ten_reciprocal_roots (x, f, n);
}
```


IBM pSeries 690 Regatta **

- Архитектура с общей памятью
 - 16 POWER4 64-bit процессоров @ 1.3GHz
 - 64 GB оперативной памяти
- Компиляция и управление задачами:
 - mpicc, mpiCC, mpif77, mpif90
 - mpisubmit -w 00:30:00 -n 16 myprog 0.01
 - llq, llcancel
- <http://www.regatta.cmc.msu.ru>

