

Introduction to MPI

2023.7.10

陈书扬, ZJUSCT

Contents

什么是MPI?

Hello, world

MPI通信函数

Profiling

什么是MPI？

消息传递接口（Message Passing Interface, MPI）是一个并行计算的应用程序接口，常在超级电脑、电脑集群等非共享内存环境程序设计。

MPI中提供了用于进程间通讯的标准接口，用于实现进程级别的并行。

MPI是一组接口标准，而不是实现。常见的MPI实现有：

- OpenMPI
- IntelMPI
- HPC-X

- MPI和OpenMP的区别？

MPI和OpenMP的区别？

```
for (int i = 0; i < 64; ++i) {  
    a[i] += i;  
}
```

```
#include <omp.h>  
#pragma omp parallel for  
for (int i = 0; i < 64; ++i) {  
    a[i] += i;  
}
```

```
#include <mpi.h>  
MPI_Init(&argc, &argv);  
int rank; // rank = [0, 64)  
MPI_Comm_rank(MPI_COMM_WORLD, &rank);  
a[rank] += rank;
```



MPI和OpenMP的区别？

OpenMP	MPI
线程间并行	进程间并行
共享内存	独立内存
初始化开销小	初始化开销大
适用于单个节点内	适用于节点间
自动分配线程任务	手动分配进程任务

Hello, World: MPI的安装

- OpenMPI: Lab1
- IntelMPI: 一般与oneAPI一起安装, 或者单独安装
- HPC-X: <https://developer.nvidia.com/networking/hpc-x>

Hello, World

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

int main(int argc, char* argv[]) {

    MPI_Init(&argc, &argv);

    int rank, size;
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);
    printf("Hello world from process %d in %d processes\n", rank, size);

    MPI_Finalize();
}
```

Hello, World -- compile and launch

compile:

```
mpicc mpi_example.c -o a.out
```

- mpicc并不是一个新的编译器
- 其他编译器: mpiicc, mpicxx, ...

launch:

```
mpirun -n 4 --host m601:2,m603:2 ./a.out
```

- 使用hostfile

应该使用多少进程？

- 理论上，最多能使用多少进程？
一般来说，进程的数量不应该超过核心的数量

```
$ lscpu
CPU(s):                64      (逻辑CPU数)
On-line CPU(s) list:  0-63
Thread(s) per core:   2      (每个核的超线程数)
Core(s) per socket:   16     (每个物理CPU的核心数)
Socket(s):            2      (物理CPU个数)
```

- 并不是在核心数量以下，进程越多越好。适当减少进程的数量可能会带来性能增益
- `cpuinfo(intelmpi)`

MPI通信函数

- 简单通信
- 非阻塞通信
- 集合通信

参考文档/网站

- <https://www.open-mpi.org/doc/v4.0/>
- mpitutorial.com
- <https://rookiehpc.org/mpi/docs/index.html>

简单通信


```
MPI_Send(void* data, int count, MPI_Datatype datatype, int destination,  
int tag, MPI_Comm communicator)
```

data	发送数据的地址
count	发送数据的元素个数
datatype	发送数据类型(MPI_INT, MPI_CHAR, MPI_FLOAT, ...)
destination	接收方的rank
tag	用于标识信息, 收发方的tag必须一致才能接收
communicator	通信域(一般为MPI_COMM_WORLD)


```
MPI_Recv(void* data, int count, MPI_Datatype datatype, int source, int  
tag, MPI_Comm communicator, MPI_Status* status)
```

tag	可以为MPI_ANY_TAG
status	关于发送方的信息(可以为MPI_STATUS_IGNORE)

简单通信：死锁



(i) 不会死锁




(j) 一定死锁

简单通信: ping pong (from mpitutorial)

```
int count = 0;
int partner = (rank + 1) % 2;
while (count < LIMIT) {
    if (rank == count % 2) {
        // Increment the ping pong count before you send it
        count++;
        MPI_Send(&count, 1, MPI_INT, partner, 0, MPI_COMM_WORLD);
        printf("rank %d sent and incremented count %d to rank %d\n",
               rank, count, partner);
    }
    else {
        MPI_Recv(&count, 1, MPI_INT, partner, 0, MPI_COMM_WORLD,
                 MPI_STATUS_IGNORE);
        printf("rank %d received count %d from rank %d\n",
               rank, count, partner);
    }
}
```

非阻塞通信（异步通信）

为什么需要非阻塞通信？



Blocking case



Non-blocking case

非阻塞通信：相关接口

```
int MPI_Isend(void* buffer, int count, MPI_Datatype datatype, int recipient, int tag, MPI_Comm communicator, MPI_Request* request);
```

```
int MPI_Irecv(void* buffer, int count, MPI_Datatype datatype, int sender, int tag, MPI_Comm communicator, MPI_Request* request);
```

测试通信是否完成：

```
int MPI_Test(MPI_Request* request, int* flag, MPI_Status* status);
```

等待通信完成：

```
int MPI_Wait(MPI_Request* request, MPI_Status* status);
```



```
int MPI_Waitall(int count, MPI_Request requests[], MPI_Status statuses[]);
```

集合通信

点对点通信 --> 单点对多点通信
多点对单点通信
多点对多点通信

- 多点的通信都可以用单点通信来实现。为什么需要专门的集合通信？


考虑广播操作（从0号进程将数据分发给所有进程）：



集合通信：接口


```
int MPI_Barrier(MPI_Comm communicator);
```

所有集合通讯在进行之前，发送数据的所有进程必须达到同一个时间点




集合通信：接口

```
int MPI_Bcast(void* buffer, int count, MPI_Datatype datatype, int emitter_rank, MPI_Comm communicator);
```




集合通信：接口

```
int MPI_Scatter(...);
```




集合通信：接口

```
int MPI_Gather(...);
```



集合通信：接口


```
int MPI_Allgather(...);
```



集合通信：接口


```
int MPI_Reduce(..., MPI_Op operation, ...);
```

MPI_Op可以为MPI_MAX, MPI_MIN, MPI_SUM, MPI_PROD(累乘)




集合通信：接口

```
int MPI_Allreduce(...);
```



集合通信：接口

```
int MPI_Alltoall(...);
```



集合通信：总结

Operation	MPI Function	Synopsis
		Individual
Send	MPI_Send	One-to-one send
Receive	MPI_Recv	One-to-one receive
Send/Receive	MPI_Sendrecv	One-to-one send/receive
		Collective
Barrier	MPI_Barrier	All wait for stragglers
Broadcast	MPI_Bcast	Root to all, all data copied
Scatter	MPI_Scatter	Root to all, slices of data copied
Gather	MPI_Gather	All to root, slices ordered on Root
Reduce	MPI_Reduce	All to root, data reduced on Root
All-Gather	MPI_Allgather	All to all, data ordered
All-Reduce	MPI_Allreduce	All to all, data reduced

Profiling(性能分析)

通过Profiling, 我们期望得到:

- 程序的瓶颈是哪一种类型? 访存/计算/通信
- 程序的每一个模块/函数分别用时多少? 消耗时间最多的是哪一部分?
- MPI通信的开销主要在哪些部分上?


Profiling(性能分析)

IntelMPI:

- Application Performance Snapshot (APS)
- Intel Trace Analyzer and Collector (ITAC)
- VTune

HPC-X:

- IPM Profiler



其他

- Process Binding
- 变长通信
- 单边通信
- ...

预告：Lab4 MPI加速PCG算法

预处理共轭梯度法(Preconditioned Conjugate Gradient method, PCG)是一种求解线性方程组 $Ax = b$ 的迭代算法，适用于稀疏矩阵的求解。广泛见于科学计算程序中。

在这个实验中，你需要：

- 使用MPI，将PCG算法并行化并尽可能加速
- 使用Profile工具对得到的MPI程序进行性能分析
- 使用Fortran完成这个实验(bonus)

Thanks for listening

2023.7.10