

Programowanie równoległe MPI

Maciej Szpindler

m.szpindler@icm.edu.pl

Interdyscyplinarne Centrum Modelowania Matematycznego i Komputerowego

Uniwersytet Warszawski

<http://www.icm.edu.pl>



Podziękowania



- Pomysły i przykłady zaczerpnięte z materiałów szkoleniowych HLRS,
 - Autor: Rolf Rabenseifner
 - https://fs.hlrs.de/projects/par/par_prog_ws/
- Materiały ze szkoleń ICM UW
 - Autorzy: Maciej Cytowski, Maciej Marchwiany
- Wykorzystane materiały z dawnego Biuletynu KDM
 - Autorzy: zespół KDM ICM UW



Zakres materiału

- Wstęp
- Message Passing Interface – podstawy
- Komunikacja point-to-point
- Komunikacja grupowa
- Komunikacja nieblokująca
- Typy danych MPI
- Konstrukcja wirtualnych topologii w MPI
- MPI-2 oraz MPI-3 – przegląd
- Komunikacja jednostronna
- Podsumowanie
- Opis zadań do ćwiczeń

Wstęp: różne pojęcia równoległości



- Różne podejścia do sprzętowego zrównoleglenia przetwarzania
 - Wektoryzacja (pipelining) na poziomie procesora
 - Duplikacja jednostek przetwarzania np. FPU na poziomie procesora
 - Wiele wątków (multi/hyper-threading) na poziomie procesora
 - Wiele rdzeni (multi-core) na poziomie procesora
 - Wiele procesorów (ccNUMA*) na poziomie systemu (pojedynczego komputera)
 - Bardzo wiele procesorów (klastry serwerów, MPP**)
- Implikacje
 - Wielowątkowość/procesorowość, wspólny dostęp do pamięci --programowanie w modelu pamięci współdzielonej
 - Klastry, sieć procesorów, pamięć rozproszona -- programowanie w modelu pamięci rozproszonej

*cache coherent Non-Uniform Memory Access

** Masively Parallel Processing

Pamięć współdzielona i rozproszona




- Poszczególne procesory (węzły) posiadają prywatną pamięć i są połączone siecią
- Komunikacja odbywa się poprzez jawną wymianę danych przez sieć
- Dziś większość klastrów posiada węzły wielo-procesorowe/rdzeniowe (ccNUMA)
- Dwa typy równoległości:
 - rozproszona – między węzłami sieci (czytaj np. *OpenMP*),
 - współdzielona – w ramach jednego węzła (czytaj np. *MPI*)

Modele programowania równoległego


- **Pamięć współdzielona (Shared Memory)**

- OpenMP
 - Dyrektywy kompilatora
 - Standard
- Biblioteki wielowątkowe – programowanie z użyciem wątków
 - Pthreads, TBB, Shmem




- **Pamięć rozproszona (Distributed Memory)**

- MPI – Message Passing Interface
 - Biblioteka do wymiany komunikatów przez sieć



- **PGAS (Partitioned Global Address Space)**

- UPC
- Co-array Fortran
- Global Arrays
- PCJ



Strategie zrównoleglania obliczeń



- Zrównoleglenie może dotyczyć
 - Danych – podział pracy względem danych w pamięci
 - Instrukcji procesora – podział pracy względem typu wykonywanych operacji
- Strategie dekompozycji obliczeń
 - Podział zadań pomiędzy procesory/procesy/wątki (task model)
 - Podział danych w rozproszonej pamięci (data decomposition)
- Wymaga to zapewnienia
 - Komunikacja między procesorami
 - Synchronizacji pamięci

- **MPI - Message Passing Interface**
 - Biblioteka zestawu procedur i funkcji zgodna ze standardem MPI
 - Standard ustala MPI-Forum
 - Pracuje natywnie z C, C++, Fortranem
 - Faktyczny standard programowania w oparciu o wymianę komunikatów
 - MPI-1 (Wersje 1.1, 1.2) – wprowadza około 150 funkcji
 - MPI-2 (Wersje 2.1, 2.2) – nowa funkcjonalność, razem ponad 500 funkcji
 - MPI-3 (Wersje 3.0, 3.1)
- Najnowsza wersja standardu 4.0 (2021):
 - <https://www.mpi-forum.org/docs/mpi-4.0/mpi40-report.pdf>
- Różne implementacje (ABI non-compatible)
 - MPICH – <http://www.mpich.org>
 - OpenMPI – <http://www.open-mpi.org>
 - Inne bazują w większości na powyższych
- Przenaszalność między implementacjami
 - <https://github.com/eschnett/MPItrampoline>

Czy to jest przestarzałe ?!

Podstawy: model równoległości




- Założenia
 - Pamięć jest rozproszona, prywatna dla każdego procesu
 - Procesy wymieniają się komunikatami
 - Jawna równoległość
- Model procesowy
 - Proces* odpowiada fizycznej jednostce obliczeniowej
 - Program składa się z procesów – podprogramów działających na poszczególnych procesorach
- Typowo model SPMD – **Single Program Multiple Data**
 - Ten sam podprogram pracuje na każdym procesorze
 - Napisany w tradycyjnym języku + wywołania biblioteki MPI
- Model MPMD mniej popularny, ale również wspierany

*Wikipedia: In computing, a **process** is an instance of a computer program that is being executed. It contains the program code and its current activity.

Podstawy: model SPMD

- SPMD – Single Program Multiple Data
 - Model zakładający dekompozycje danych
 - Każdy proces (podprogram) wykonują identyczny zestaw operacji ale na innym zbiorze danych
 - Wymaga dekompozycji problemu na szereg identycznych podproblemów
- Najpopularniejszy model zrównoleglania dla MPI
- Różnice terminologiczne:
 - Task (SLURM), Worker (Matlab),



Podstawy: komunikator

- Podstawowa struktura programu równoległego używającego MPI
- **Komunikator** – abstrakcja opisująca kontekst oraz zbiór (grupe) procesów mogących się wzajemnie komunikować
- W ramach komunikatora każdy proces należy do grupy z unikalnym identyfikatorem (numerem) tzw. **rank**
- Informacja o komunikatorze zawarta jest w zmiennej typu **MPI_COMM**
- W czasie inicjacji programu biblioteka tworzy domyślny komunikator o nazwie **MPI_COMM_WORLD** zawierający wszystkie dostępne procesy oraz **MPI_COMM_SELF** zawierający tylko lokalny proces
- Programista może definiować własne komunikatory zawierające podzbiory procesów

Podstawy: grupa procesów



Grupa definiuje uporządkowany zbiór procesów (każdy posiadający unikalny numer - rank). Grupy definiują zakres procesów zaangażowanych w operacje komunikacyjne. Grupami można zarządzać niezależnie od komunikatorów MPI, ale tylko komunikatory pozwalają na wykonanie komunikacji.

Zarządzanie grupami, przykłady operacji:

- `MPI_COMM_GROUP`
- `MPI_COMM_CREATE_FROM_GROUP`

Podstawy: schemat graficzny



INTERCONNECT



Proces <PID1>

Rank 0



Thread 0

Thread 1



Proces <PID2>

Rank 1



Thread 0

Thread 1

Node 1



Proces <PID1>

Rank 2



Thread 0

Thread 1



Proces <PID2>

Rank 3



Thread 0

Thread 1

Node 2

COMM1

Pobieranie informacji z komunikatora

- Liczba (np) dostępnych procesów w ramach komunikatora

`MPI_Comm_size (MPI_COMM_WORLD, &np)`

- Numer (rank) mojego procesu

`MPI_Comm_rank (MPI_COMM_WORLD, &rank)`

- (Uwaga Fortran) rank = 0, ..., np – 1

C:

```
int MPI_Comm_size ( MPI_Comm comm, int *np );  
int MPI_Comm_rank ( MPI_Comm comm, int *rank );
```

Fortran:

```
CALL MPI_COMM_SIZE ( integer comm, integer np, integer ierror )  
CALL MPI_COMM_RANK ( integer comm, integer rank, integer ierror )
```

Startowanie i zamykanie sesji

- Wywołania wszelkich funkcji i procedur biblioteki MPI muszą znajdować się pomiędzy instrukcjami:

MPI_Init(&argc, &argv)

- Inicjuje działanie biblioteki i domyślny komunikator (sesję)

MPI_Finalize(void)

- Kończy sesję (program) MPI

- Funkcje **Init** i **Finalize** muszą być wywołane przez wszystkie procesy w ramach sesji

C:

```
int MPI_Init ( int *argc, int **argv  );  
int MPI_Finalize ( );
```

Fortran:


```
CALL MPI_INIT( integer ierror )  
CALL MPI_FINALIZE ( integer ierror )
```

Message Passing Interface - komunikaty



- Komunikaty
- Podstawowe typy danych w MPI
- Przesyłanie wiadomości

- Komunikat – paczka danych przesyłana pomiędzy procesami przez łącze / sieć łącząca procesory w ramach komunikatora
- Paczka składa się z ustalonej liczby elementów określonego typu
- Aby przesłać paczkę należy zdefiniować:
 - Identyfikator (**rank**) procesu wysyłającego
 - Identyfikator (**rank**) procesu odbierającego
 - Adres źródłowy i adres docelowy
 - Typ i wielkość danych przesyłanych w paczce
 - Komunikator



Podstawowe typy danych

- MPI definiuje własne typy danych, które powinny być odpowiednikami typów w C
- Dodatkowo `MPI_BYTE` oraz `MPI_PACKED`

Typ MPI	Typ języka C
<code>MPI_CHAR</code>	signed char
<code>MPI_SHORT</code>	signed short int
<code>MPI_INT</code>	signed int
<code>MPI_LONG</code>	signed long int
<code>MPI_UNSIGNED_CHAR</code>	unsigned char
<code>MPI_UNSIGNED_SHORT</code>	unsigned short int
<code>MPI_UNSIGNED</code>	unsigned int
<code>MPI_UNSIGNED_LONG</code>	unsigned long int
<code>MPI_FLOAT</code>	float
<code>MPI_DOUBLE</code>	double
<code>MPI_LONG_DOUBLE</code>	long double

Typ MPI	Typ Fortran
<code>MPI_INTEGER</code>	INTEGER
<code>MPI_REAL</code>	REAL
<code>MPI_DOUBLE_PRECISION</code>	DOUBLE PRECISION
<code>MPI_COMPLEX</code>	COMPLEX
<code>MPI_LOGICAL</code>	LOGICAL
<code>MPI_CHARACTER</code>	CHARACTER(1)

Wysyłanie wiadomości



- **buf** – adres tablicy zawierającej wiadomość długości **count**, zawierającej elementy typu **datatype**
- **dest** – numer (rank) procesu odbierającego w ramach komunikatora **comm**
- **tag** – etykieta wiadomości

C:

```
int MPI_Send ( void *buf, int count, MPI_Datatype datatype, \
               int dest, int tag, MPI_Comm comm );
```

Fortran:

```
CALL MPI_SEND ( <type> buf, integer count, integer datatype,
                integer dest, integer tag, integer comm,
                integer ierror )
```

Odbieranie wiadomości

- **buf** – adres tablicy zawierającej wiadomość długości **count**, zawierającej elementy typu **datatype**
- **source** – numer (rank) procesu wysyłającego w ramach komunikatora **comm**
- **status** – zawiera informacje o komunikacji (struktura zawierająca `MPI_SOURCE` i `MPI_TAG`)
- Jedynie wiadomość o zgodnej etykiecie (**tag**) zostanie odebrana

C:

```
int MPI_Recv ( void *buf, int count, MPI_Datatype datatype, \
               int source, int tag, MPI_Comm comm, \
               MPI_Status *status);
```

Fortran:

```
CALL MPI_RECV ( <type> buf, integer count, integer datatype,
                integer source, integer tag, integer comm,
                integer status, integer ierror )
```

Przesyłanie komunikatów

- Podstawowa metoda przesłania komunikatu pomiędzy dwoma procesami
 - Nadawca wywołuje funkcję **Send**
 - Odbiorca wywołuje funkcję **Receive**
- Poszczególne komunikaty odróżnia etykieta (**tag**)
- `MPI_Send` / `MPI_Recv` to funkcje blokujące tzn. blokują dalsze wykonanie programu do czasu zakończenia komunikacji

Komunikacja point-to-point

- Najprostsza forma komunikacji
- Proces wysyła komunikat do innego wybranego procesu
- Różne tryby komunikacji point-to-point (blokującej)
 - Standardowa: `MPI_Send`
 - Synchroniczna: `MPI_Ssend`
 - Asynchroniczna / buforowana: `MPI_Bsend`
 - Ready send: `MPI_Rsend`
 - różnią się tym jak restrykcyjna ma być synchronizacja
 - Wszystkie powyższe tryby są blokujące – wysyłanie kończy się w momencie gdy użytkownik może bezpiecznie odczytać i modyfikować bufor wejściowy (tablicę zawierającą komunikat)
- Odbieranie **`MPI_Recv`** działa ze wszystkimi trybami wysyłania

Komunikacja point-to-point : tryby wysyłania komunikatów

Tryb wysyłania		Działanie
Synchroniczny MPI_Ssend		Pełna synchronizacja, nie zakłada wcześniejszego wywołania MPI_Recv, zakończy wykonanie, gdy odbiorca rozpocznie odbieranie
Standardowy MPI_Send		Wysyłanie blokujące, biblioteka decyduje o użyciu wewnętrznego bufora
Buforowany MPI_Bsend		Korzysta z bufora użytkownika, nie wymaga wcześniejszego wywołanie MPI_Recv, zakończy wykonanie po umieszczeniu wiadomości w buforze
Ready send MPI_Rsend		Zakłada wcześniejsze wywołanie MPI_Recv

Komunikacja point-to-point : tryby wysyłania komunikatów (2)



- Generyczny **MPI_Send**
 - Biblioteka MPI zadecyduje o trybie wysyłki
 - Zapewnia minimalny czas transferu
- Wysyłanie buforowane **MPI_Bsend**
 - Wymaga zapewnienia przez użytkownika bufora odpowiedniej wielkości
 - `MPI_Buffer_attach` tworzy bufor,
 - `MPI_Buffer_detach` zwalnia bufor
 - W przypadku przepełnienia bufora nastąpi błąd
 - Niskie opóźnienie kosztem przepustowości
- Synchroniczne wysyłanie **MPI_Ssend**
 - Ryzyko zakleszczenia
 - Najlepsza przepustowość kosztem opóźnień lub przestojów
- „Ready send” **MPI_Rsend**
 - Zakończy się błędem, jeżeli nie wystąpi wcześniej odpowiednie wywołanie `MPI_Recv`
 - Niebezpieczne dla poprawności, nie zalecane do użycia
 - Potencjalnie najszybsze

Komunikacja wieloznaczna



- Odbiorca może odbierać komunikaty w niezdefiniowanej kolejności
 - Od dowolnego odbiorcy (rank): **MPI_ANY_SOURCE**
 - Z dowolną etykietą (tag): **MPI_ANY_TAG**
- Faktyczny identyfikator nadawcy / tag odbiorca może odczytać z parametru `status` zwracanego przez `MPI_Recv`
- **MPI_Probe** pozwala na uzyskanie informacji o komunikacie bez odbierania go (przed wywołaniem `MPI_Recv`), informacja zwracana jest poprzez parametr `status`

C:

```
int MPI_Probe (int source, int tag, MPI_Comm comm, \
               MPI_Status *status);
```

Fortran:

```
CALL MPI_PROBE (INTEGER SOURCE, TAG, COMM, STATUS(MPI_STATUS_SIZE),  
IERROR)
```

Komunikacja grupowa (kolektywna)



- Komunikacja grupowa, czyli taka, w której uczestniczy grupa procesów MPI
- Dana funkcja wywoływana jest przez wszystkie procesy w komunikatorze
- W MPI wyróżniamy następujące typy komunikacji grupowej:
 - Bariera synchronizacyjna
 - operacja Broadcast – nadaj wiadomość wielu procesom
 - operacja typu rozrzuć (z ang. scatter)
 - operacja typu zbierz (z ang. gather)
 - operacja wszyscy do wszystkich
 - operacja redukcji (np. globalna suma, globalne maksimum,..)

Komunikacja grupowa: bariera synchronizacyjna



- Zwykle bariera nie jest potrzebna, gdyż odpowiednia synchronizacja powinna być zapewniona na bazie interfejsu przesyłania komunikatów
- Może być używana do:
 - debugowania programów równoległych
 - profilingu programów równoległych
 - synchronizacji do operacji I/O

C:


```
int MPI_Barrier(MPI_Comm comm);
```

Fortran:

```
CALL MPI_BARRIER(integer comm, integer ierror)
```

Komunikacja grupowa: Broadcast

- Operacja polegająca na rozesyłaniu tej samej wiadomości do wszystkich procesów grupy



C:


```
int MPI_Bcast(void* buffer, int count, MPI_Datatype datatype, int
root, MPI_Comm comm);
```

Fortran:

```
CALL MPI_BCAST(choice buffer, integer count, integer datatype, integer
root, integer comm, integer ierror)
```

Komunikacja grupowa: Scatter

- Operacja polegająca na rozstawianiu przez proces `root` wektora `sendbuf` podzielonego na kawałki `sendcount` do procesów w grupie (również do siebie)



C:


```
int MPI_Scatter(void* sendbuf, int sendcount, MPI_Datatype  
sendtype, void* recvbuf, int recvcount, MPI_Datatype recvtype, int  
root, MPI_Comm comm);
```

Fortran:

```
CALL MPI_SCATTER(choice sendbuf, integer sendcount, integer sendtype,  
choice recvbuf, integer recvcount, integer recvtype, integer root,  
integer comm, integer ierror)
```

Komunikacja grupowa: Gather

- Operacja odwrotna do scatter, czyli zebranie kawałków wektora z procesorów w grupie i zapisanie ich w buforze wybranego procesora



C:

```
int MPI_Gather(void* sendbuf,int sendcount,MPI_Datatype sendtype,  
void* recvbuf,int recvcount,MPI_Datatype recvtype,int root, MPI_Comm  
comm);
```

Fortran:

```
CALL MPI_GATHER(choice sendbuf, integer sendcount, integer sendtype,  
choice recvbuf, integer recvcount, integer recvtype, integer root,  
integer comm, integer ierror)
```

Komunikacja grupowa: wszyscy do wszystkich



- Każdy z procesów wysyła do procesu i -tego `sendcount` kolejnych elementów typu `sendtype`, poczynając od elementu $i*\text{sendtype}$ tablicy `sendbuf`

C:

```
int MPI_Alltoall( void *sendbuf, int sendcount, MPI_Datatype
                  sendtype, void *recvbuf, int recvcount,
MPI_Datatype recvtype, MPI_Comm comm )
```

Fortran:

```
CALL MPI_ALLTOALL(choice sendbuf, integer sendcount, integer
sendtype, choice recvbuf, integer recvcount, integer recvtype,
integer comm, integer ierror)
```

Komunikacja grupowa: operacja redukcji



- Służy do wykonywania globalnej operacji na elementach procesów należących do grupy
- Operacja typu: $d_0 \circ d_1 \circ d_2 \circ \dots \circ d_{n-1}$
 - d_i to dane w procesie o numerze i (skalar lub wektor)
 - $\circ$ to pewna zdefiniowana operacja
- Istnieje możliwość skorzystania z gotowych definicji operacji takich jak suma czy maksimum
- Istnieje możliwość zdefiniowania własnych operacji funkcją `MPI_Op_create(...)`

Komunikacja grupowa: przykład – globalna suma



- Chcemy dokonać sumowania pewnej wartości zawartej w `inbuf` po wszystkich procesach w grupie
- Użyjemy operacji `MPI_SUM`
- Wynik ma zostać zwrócony na `resultbuf`

C:

```
int MPI_Reduce( &inbuf, &resultbuf, 1, MPI_INT, MPI_SUM, root,
MPI_COMM_WORLD );
```

Fortran:

```
CALL MPI_REDUCE( inbuf, resultbuf, 1, MPI_INTEGER, MPI_SUM,
root, MPI_COMM_WORLD, ierror)
```

- Dostępna jest również operacja **MPI_ALLREDUCE** (bez parametru `root`), która jest połączeniem operacji Reduce i Broadcast – zwraca wynik w każdym procesie

Komunikacja grupowa: dostępne operacje redukcji



Nazwa operacji	Funkcja
MPI_MAX	Maksimum
MPI_MIN	Minimum
MPI_SUM	Suma
MPI_PROD	Iloczyn
MPI LAND	Logiczna koniunkcja
MPI_BAND	Koniunkcja binarna
MPI_LOR	Logiczna alternatywa
MPI BOR	Alternatywa binarna
MPI_LXOR	Logiczna alternatywa wykluczająca
MPI_BXOR	Binarna alternatywa wykluczająca
MPI_MAXLOC	Maksimum i jego pozycja
MPI_MINLOC	Minimum i jego pozycja

Blokada (deadlock)

- 0** Wywołuje: MPI_Ssend i czeka aż odbiorca (1) rozpocznie odbieranie
- 1** Wywołuje: MPI_Ssend i czeka aż odbiorca (0) rozpocznie odbieranie



- **Nikt nie odbiera!**
- Komunikacja odbywa się w trybie blokującym
- Ssend czeka na rozpoczęcie odbierania (Recv)
- **Rozwiązanie**
- Wywołać Send/Recv naprzemiennie
- Użyć funkcji **MPI_Sendrecv**
- Użyć komunikacji **nieblokującej**

Komunikacja nieblokująca



- zwróć wykonanie do procesu od razu i pozwól na wykonywanie innej pracy
- w dalszej części proces powinien sprawdzić (**test**) lub poczekać (**wait**) na zakończenie operacji nieblokującej – są to operacje wymagane
- operacja nieblokująca + następująca po niej od razu operacja **wait** = operacja blokująca
- stosowane w celu uniknięcia impasów (blokad, z ang. deadlocks) oraz bezczynności

Komunikacja nieblokująca (2)

- Komunikacja realizowana w **3 krokach**:
 1. inicjalizacja nieblokującej komunikacji
 - natychmiast zwraca wykonanie do procesu
 - nazwa funkcji rozpoczyna się od **MPI_I...** (immediate)
 2. wykonanie pracy, obliczenia, inna komunikacja
 3. czekanie na zakończenie komunikacji nieblokującej
- Nieblokujące wysłanie:

```
MPI_Isend(...)  
//wykonanie pracy  
MPI_Wait(...)
```

- Nieblokujący odbiór:

```
MPI_Irecv(...)  
//wykonanie pracy  
MPI_Wait(...)
```

Komunikacja nieblokująca: wysłanie



C:

```
int MPI_Isend( void *buf, int count, MPI_Datatype datatype,
               int dest, int tag, MPI_Comm comm,
               MPI_Request *request );

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

Fortran:

```
CALL MPI_ISEND( choice buf, integer count, integer datatype,
                integer dest, integer tag, integer comm,
                integer request, integer ierror )

CALL MPI_WAIT( integer request, integer
               status(MPI_STATUS_SIZE), integer ierror )
```

Komunikacja nieblokująca: odbiór



- **UWAGA:** **buf** nie powinien być używany pomiędzy **Irecv** a operacją **wait**

C:

```
int MPI_Irecv( void *buf, int count, MPI_Datatype datatype,
               int source, int tag, MPI_Comm comm,
               MPI_Request *request );

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

Fortran:

```
CALL MPI_ISEND( choice buf, integer count, integer datatype,
                integer source, integer tag, integer comm,
                integer request, integer ierror )

CALL MPI_WAIT( integer request, integer
               status(MPI_STATUS_SIZE), integer ierror )
```

Komunikacja nieblokująca: uwaga na Fortran!



- Kompilatory Fortran wykorzystują intensywną optymalizację (tzw. Register Optimization) zmieniająca kod programu bez naszej wiedzy
- Kod:

```
CALL MPI_Irecv( buf, ... , request, ierror)

CALL MPI_WAIT(request, status, ierror )

WRITE(*,*) buf
```

- Może zostać zamieniony na:

```
CALL MPI_Irecv( buf, ... , request, ierror)
registerA = buf
CALL MPI_WAIT(request, status, ierror )
WRITE(*,*) registerA
```

- **Potencjalne źródło błędów trudnych do wykrycia**
- Rozwiązanie: wywołać **MPI_Get_address(buf, ...)** bezpośrednio po MPI_Wait

Komunikacja nieblokująca: synchronizacja



- Oczekiwanie na zakończenie operacji nieblokujących:
 - z użyciem blokującej funkcji **MPI_Wait**
 - z użyciem pętli, w której sprawdzamy wartość flagi zwróconej z wywołania funkcji **MPI_Test** (`flag == 1` lub `.TRUE.`)

C:

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

Fortran:

```
CALL MPI_WAIT( integer request, integer  
               status(MPI_STATUS_SIZE), integer ierror )  
  
CALL MPI_TEST( integer request, integer flag, integer  
               status(MPI_STATUS_SIZE), integer ierror)
```

Komunikacja nieblokująca: request handles



- Zmienne typu **MPI_Request** (Fortran - Integer) służą do synchronizacji komunikacji nieblokującej
- Muszą być zmiennymi lokalnymi
- Wartość zmiennej typu request jest
 - generowana przez nieblokującą funkcję komunikacyjną
 - używana i zwalniana przez funkcję MPI_Wait

Komunikacja nieblokująca i blokująca



- Wysyłanie i odbieranie może być blokujące lub nieblokujące
- Blokujące wysyłanie może być użyte z nieblokującym odbieraniem i vice-versa
- Nieblokujące wysyłanie może używać trybów analogicznych do blokującego
 - Generyczne **MPI_Isend**
 - Synchroniczne **MPI_Issend**
 - Buforowane **MPI_Ibsend**
 - Ready send **MPI_Irsend**
- W każdym z tych trybów sterowanie jest zwracane od razu (immediate) do programu
- Operacja nieblokująca i bezpośrednio następujące wait jest równoważne analogicznej operacji blokującej

Komunikacja nieblokująca: wiele komunikatów



- Kilka funkcji operujących na grupie komunikacji nieblokujących:
 - poczekaj na zakończenie lub sprawdź status jednej wiadomości z grupy:

```
int MPI_Waitany(int count, MPI_Request array_of_requests[], int *index,  
                MPI_Status *status )  
int MPI_Testany(int count, MPI_Request array_of_requests[], int *index,  
                int *flag, MPI_Status *status )
```

- poczekaj na zakończenie lub sprawdź status wszystkich wiadomości z grupy:

```
int MPI_Waitall(int count, MPI_Request array_of_requests[], MPI_Status  
                array_of_statuses[] )  
int MPI_Testall(int count, MPI_Request array_of_requests[], int *flag,  
                MPI_Status array_of_statuses[] )
```

- poczekaj na zakończenie lub sprawdź status tylu wiadomości ile jest możliwe:

```
int MPI_Waitsome(int incount, MPI_Request array_of_requests[], int  
                 *outcount, int array_of_indices[], MPI_Status  
                 array_of_statuses[])  
int MPI_Testsome(int incount, MPI_Request array_of_requests[], int  
                 *outcount, int array_of_indices[], MPI_Status  
                 array_of_statuses[])
```

Typy danych w MPI

- Typy określają sposób ułożenia przesyłanych i odbieranych wiadomości w pamięci

```
int MPI_Isend(&buf, 1, MPI_FLOAT, 0, tag, MPI_COMM_WORLD, &req);
```

- Rozróżniamy:
 - typy podstawowe zdefiniowane w ramach biblioteki MPI
MPI_CHAR, MPI_SHORT, MPI_INT, MPI_LONG,
MPI_UNSIGNED_CHAR, MPI_UNSIGNED_SHORT, MPI_UNSIGNED,
MPI_UNSIGNED_LONG, MPI_FLOAT, MPI_DOUBLE,
MPI_LONG_DOUBLE, MPI_BYTE
 - typy upakowane, specyfikowane przez MPI_PACKED
 - typy definiowalne, np. wektory, struktury, inne

Typy danych: typy podstawowe

Typ MPI	Typ języka C
MPI_CHAR	signed char
MPI_SHORT	signed short int
MPI_INT	signed int
MPI_LONG	signed long int
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED_SHORT	unsigned short int
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_LONG_DOUBLE	long double
MPI_BYTE	
MPI_PACKED	

Typ MPI	Typ Fortran
MPI_INTEGER	INTEGER
MPI_REAL	REAL
MPI_DOUBLE_PRECISION	DOUBLE PRECISION
MPI_COMPLEX	COMPLEX
MPI_LOGICAL	LOGICAL
MPI_CHARACTER	CHARACTER(1)
MPI_BYTE	
MPI_PACKED	

Typy danych: typy MPI

- Typ danych wyspecyfikowany w komendzie send powinien dokładnie odpowiadać typowi wyspecyfikowanemu w komendzie recv
- **MPI_BYTE** = 8 znaków binarnych
- **MPI_PACK** umożliwia pakowanie elementów różnych typów do jednego bufora
- **MPI_PACK** może również reprezentować dowolny typ danych
- Jeśli nasza wiadomość nie jest tablicą elementów określonego typu, tylko niejednorodną wiadomością zawierającą np. dwie liczby całkowite i tablicę liczb zmiennoprzecinkowych, wówczas musimy skorzystać z jednego z dwóch mechanizmów tworzenia takich wiadomości:
 - pakowanie danych
 - tworzenie własnych typów danych MPI

Typy danych: Pakowanie danych



- MPI udostępnia możliwość przesłania bufora pamięci zawierającego spakowane elementy różnych typów
- Przesłanie takiego elementu wykonujemy przy użyciu typu **MPI_PACKED**
- Aby wykorzystać ten mechanizm należy:
 - Spakować dane za pomocą funkcji **MPI_PACK**
 - Przesłać bufor pamięci za pomocą komendy **send**
 - Odebrać bufor pamięci za pomocą komendy **recv**
 - Rozpakować dane za pomocą komendy **MPI_UNPACK**
- Rozwiązanie dosyć wygodne, ale związane z kopiowaniem danych do nowego miejsca w pamięci

Typy danych: Pakowanie danych (2)



C:

```
int MPI_Pack ( void *inbuf, int incount, MPI_Datatype datatype,  
void *outbuf, int outcount, int *position, MPI_Comm comm )
```

Fortran:

```
CALL MPI_PACK(choice inbuf, integer incount, integer datatype,  
choice outbuf, integer outsize, integer position, integer comm,  
integer ierror)
```

- Pakowanie danych do bufora
 - inkrementalne dodawanie elementów do bufora
 - pakowanie do bufora o nazwie `outbuf` i rozmiarze `outcount`, począwszy od pozycji `position`, danych w liczbie `incount` pochodzących z bufora `inbuf` o typie `datatype`
 - dodatkowo istnieje możliwość skorzystania z grup komunikatorów (np. grup odpowiadających architekturom procesorów)
 - argument `position` musi zostać przekazany przez adres, gdyż zwracane jest na nim pozycja w buforze wyjściowym po dodaniu nowego elementu (w bajtach)

Typy danych: Pakowanie danych (3)



- Aby przygotować bufor wyjściowy odpowiedniej wielkości możemy wpierw sprawdzić wymagany rozmiar za pomocą funkcji **MPI_Pack_Size**
- Funkcja ta zapisuje pod zmienną `size` ilość bajtów potrzebną do upakowania `incount` elementów typu `datatype`

C:

```
int MPI_Pack_size (int incount, MPI_Datatype datatype, MPI_Comm comm, int *size )
```

Fortran:

```
CALL MPI_PACK_SIZE(integer incount, integer datatype, integer comm, integer size, integer ierror)
```

- Do rozpakowania danych z przesłanego bufora możemy użyć funkcji **MPI_Unpack**

C:

```
int MPI_Unpack ( void *inbuf, int insize, int *position, void *outbuf, int outcount, MPI_Datatype datatype, MPI_Comm comm )
```

Fortran:

```
CALL MPI_UNPACK(choice inbuf, integer insize, integer position, choice outbuf, integer outcount, integer datatype, integer comm, integer ierror)
```

Typy danych: przykład pakowania danych

C:

```
int position, i, j, a[2];
char buff[1000];

....

MPI_Comm_rank(MPI_COMM_WORLD, &myrank);

if (myrank == 0) {
    ...
    position = 0;
    MPI_Pack(&i, 1, MPI_INT, buff, 1000, &position, MPI_COMM_WORLD);
    MPI_Pack(&j, 1, MPI_INT, buff, 1000, &position, MPI_COMM_WORLD);
    MPI_Send( buff, position, MPI_PACKED, 1, 0, MPI_COMM_WORLD);
} else /* RECEIVER CODE */
    MPI_Recv( a, 2, MPI_INT, 0, 0, MPI_COMM_WORLD)
}
```

Typy danych: definiowalne typy MPI

- MPI umożliwia nam definiowanie 3 rodzajów własnych typów:
 - typy reprezentujące ciągły fragment pamięci zawierający elementy tego samego typu – `MPI_Type_Contiguous`



- typy będące wektorami elementów danego typu, które nie reprezentują ciągłego fragmentu pamięci – `MPI_Type_Vector`




- typy będące strukturami zawierającymi elementy różnych typów, które niekoniecznie reprezentują ciągły fragment pamięci – `MPI_Type_Struct`



Typy danych: ciągłe fragmenty pamięci



- Najprostszy definiowalny typ danych MPI



C:

```
int MPI_Type_contiguous(int count, MPI_Datatype oldtype, MPI_Datatype
*newtype);
```

Fortran:

```
CALL MPI_TYPE_CONTIGUOUS(integer count, integer oldtype, integer
newtype, integer ierror)
```

Typy danych: typ wektorowy

- Używane jeśli interesujące nas wektory danego typu nie reprezentują ciągłego fragmentu pamięci, np. pomiędzy nimi znajdują się elementy, które nie powinny być przesłane/odebrane



blocklength = 3 elementy na blok



stride= 4 (co ile występuje nowy element)



count = 3 bloki

C:


```
int MPI_Type_vector(int count,int blocklength,int stride, MPI_Datatype  
oldtype,MPI_Datatype *newtype);
```

Fortran:

```
CALL MPI_TYPE_VECTOR(integer count, integer blocklength, integer  
stride, integer oldtype, integer newtype, integer ierror)
```

Typy danych: struktury

- Używane do przesyłania struktur zawierających elementy różnego typu, które niekoniecznie reprezentują ciągły fragment pamięci



C:

```
int MPI_Type_struct(int count, int *array_of_blocklengths, MPI_Aint
*array_of_displacements, MPI_Datatype *array_of_types, MPI_datatype
*newtype);
```

Fortran:

```
CALL MPI_TYPE_STRUCT(integer count, integer array_of_blocklengths(*),
integer array_of_displacements(*), integer array_of_types(*), integer
newtype, integer ierror)
```

Typy danych: struktury (2)

- Aby obliczyć przemieszczenie potrzebne są nam adresy poszczególnych bloków
 - Możemy do tego celu użyć funkcji MPI

MPI-1

C:

```
int MPI_Address(void* location, MPI_Aint *address);
```

Fortran:

```
CALL MPI_ADDRESS(choice location, integer address, integer ierror)
```

Usunięte w MPI-3


MPI-2

C:

```
int MPI_Get_address(void *location, MPI_Aint *address);
```

Fortran:

```
CALL MPI_GET_ADDRESS(choice location(*), integer  
(KIND=MPI_ADDRESS_KIND) address, integer ierror)
```



Typy danych: zatwierdzenie nowego typu



- Zanim użyjemy nowego typu danych MPI, **musimy go zatwierdzić za pomocą komendy `MPI_TYPE_COMMIT`**
- Musi być to wykonane tylko raz dla każdego procesu MPI

C:


```
int MPI_Type_commit(MPI_Datatype *datatype);
```

Fortran:

```
CALL MPI_TYPE_COMMIT(integer datatype, integer ierror)
```

Wirtualne topologie

- Wirtualne topologie to mechanizm pozwalający nazywać procesy w komunikatorze w sposób, który lepiej pasuje do schematu komunikacji pomiędzy procesami
- Wirtualnych topologii użyjemy na przykład jeśli obliczenia wykonywane są na dwu-wymiarowej siatce i każdy proces komunikuje się tylko i wyłącznie ze swoimi najbliższymi sąsiadami w siatce



Topologia kartezjańska (periodyczna siatka dwuwymiarowa)

Wirtualne topologie (2)

- Za mechanizmem wirtualnych topologii kryje się czysta arytmetyka liczb całkowitych
- Zyski ze stosowania tego mechanizmu:
 - Prostszy kod
 - Zmienne odwzorowujące schemat komunikacji
 - umożliwia lepszą wydajność – podpowiadamy bibliotece jak wygląda schemat komunikacji
- Nowa topologia tworzy nowy komunikator
- MPI zapewnia funkcje mapowania indeksów
 - w celu obliczenia numeru procesu na podstawie nazewnictwa stosowanego w topologii
 - w celu obliczenia współrzędnych w topologii na podstawie numeru procesu (topologia kartezjańska)

Wirtualne topologie: rodzaje



- Topologie kartezjańskie
 - Każdy proces jest połączony z sąsiadami w wirtualnej siatce
 - Brzegi mogą być periodyczne (cykliczne, z zapętleniem) lub bez
 - Procesy są identyfikowane współrzędnymi kartezjańskimi w formie $(x_1, x_2, \dots)$
- Topologie grafowe
 - Dowolne grafy
 - Dwie formy
 - **GRAPH** (MPI-1)
 - **DIST_GRAPH** (skalowalna wersja MPI-2.2 i MPI-3)

Wirtualne topologie: topologie kartezjańskie



- Utworzenie nowego komunikatora o topologii kartezjańskiej
- `ndims` – wymiar topologii kartezjańskiej (1 – pierścień, 2 – cylinder lub siatka 2D, 3 – torus lub siatka 3D)
- `dims` – tablica definiująca liczbę procesów w każdym wymiarze
- `periods` – tablica definiująca czy siatka zawiera zapętlenia w każdym z wymiarów
- `reorder` – czy pozwalamy na zmianę numerów procesów w nowym komunikatorze

C:

```
int MPI_Cart_create ( MPI_Comm comm_old, int ndims, int *dims, int  
*periods, int reorder, MPI_Comm *comm_cart )
```

Fortran:

```
CALL MPI_CART_CREATE(INTEGER COMM_OLD, INTEGER NDIMS, INTEGER DIMS(*),  
INTEGER PERIODS(*), INTEGER REORDER, INTEGER COMM_CART, INTEGER IERROR)
```

Wirtualne topologie: mapowanie procesów



C:

```
int MPI_Cart_coords ( MPI_Comm comm, int rank, int maxdims, int
*coords )
```

Fortran:

```
CALL MPI_CART_COORDS (INTEGER COMM, INTEGER RANK, INTEGER MAXDIMS,
INTEGER COORDS (*), INTEGER IERROR)
```

C:

```
int MPI_Cart_rank( MPI_Comm comm, int *coords, int *rank )
```

Fortran:

```
CALL MPI_CART_RANK (INTEGER COMM, INTEGER COORDS (*), INTEGER RANK,
INTEGER IERROR)
```

- Funkcja zapisuje pod adresem `rank` numer procesu o współrzędnych określonych w tablicy `coords`.

Wirtualne topologie: procesy sąsiednie EURO

- Funkcja ta przesuwa numer lokalnego procesu wzdłuż wyspecyfikowanego wymiaru, w celu wygenerowania numerów procesów źródłowego i docelowego
- Numer źródła otrzymany jest poprzez odjęcie `displ` od n-tej współrzędnej lokalnego procesu, gdzie n równe jest `direction`. Numer docelowego procesu otrzymywany jest poprzez dodawanie `disp` do n-tej współrzędnej.
- **Współrzędne numerowane są od zera.**

C:

```
int MPI_Cart_shift ( MPI_Comm comm, int direction, int displ, int
*source, int *dest )
```

Fortran:

```
CALL MPI_CART_SHIFT(INTEGER COMM,INTEGER DIRECTION,INTEGER DISP,
INTEGER RANK_SOURCE,INTEGER RANK_DEST,INTEGER IERROR)
```

- Znajdowanie sąsiadów w topologii kartezyjskiej


Wirtualne topologie: procesy sąsiednie (2)



- Jeśli topologia nie jest periodyczna w wybranym wymiarze, to przy wyliczeniach sąsiadów procesorów brzegowych zostanie zwrócona wartość **MPI_PROC_NULL**
- **MPI_PROC_NULL** jest także poprawnym identyfikatorem (rank) odbiorcy lub nadawcy przy komunikacji
- W takim przypadku komunikacja nie następuje ale może to znacznie uprościć kod (nie wymaga odróżniania przypadków na brzegu siatki)

Wirtualne topologie: podziały kartezjańskie

- Podział siatki na przekroje wzdłuż wybranego wymiaru
- Każdy przekrój tworzy nowy komunikator
- W ramach każdego przekroju można wykonać dedykowaną komunikację kolektywną (następny rozdział)



Wirtualne topologie: podziały kartezyjskie (2)



- Tworzy podzbiór siatki (nowy komunikator o topologii kartezyjskiej)
- Nowy komunikator zawierający przekroje siatki dla wymiarów odpowiadających elementom tablicy `remain_dims` (1 – ten wymiar pozostaje w nowym komunikatorze, 0 – ten wymiar nie uczestniczy w nowym komunikatorze)

C:

```
int MPI_Cart_sub ( MPI_Comm comm_cart, int* remain_dims, MPI_Comm*  
comm_sub)
```

Fortran:

```
CALL MPI_CART_SUB(INTEGER COMM_CART, INTEGER REMAIN_DIMS(*), INTEGER  
COMM_SLICE, INTEGER IERROR)
```

Podziały komunikatorów



MPI_Comm_split_type - dzieli komunikator na rozłączne podzbiory według określonego parametru:

- `MPI_COMM_TYPE_SHARED`

This type splits the communicator into subcommunicators, each of which can create a shared memory region.

Nowe w standardzie 4.0:

- `MPI_COMM_TYPE_HW_GUIDED`—this value specifies that the communicator `comm` is split according to a hardware resource type (for example a computing core or an L3 cache) specified by the "mpi_hw_resource_type" info key.
- `MPI_COMM_TYPE_HW_UNGUIDED`—the group of MPI processes associated with `newcomm` must be a strict subset of the group associated with `comm` and each `newcomm` corresponds to a single instance of a hardware resource type (for example a computing core or an L3 cache).

MPI i wątki

- Standard MPI-3 określa wszystkie funkcje MPI jako **thread-safe**
- Operacje blokujące blokują wykonanie tylko wywołującego wątku
- Specjalna forma inicjalizacji MPI zalecana przy użyciu wątków

C:

```
int MPI_Init_thread (int *argc, char ***argv, int required, \
                    int *provided)
```

Fortran:

```
CALL MPI_INIT(INTEGER REQUIRED, INTEGER PROVIDED, INTEGER IERROR)
```

- Argument `required` określa pożądaną poziom współpracy biblioteki z wątkami,
- faktyczny poziom wsparcia zwraca `provided`
 - **MPI_THREAD_SINGLE** tylko jeden wątek per proces (brak wsparcia)
 - **MPI_THREAD_FUNNELED** tylko jeden wątek w ramach procesu używa MPI
 - **MPI_THREAD_SERIALIZED** tylko jeden wątek **jednocześnie** używa MPI
 - **MPI_THREAD_MULTIPLE** pełne wsparcie dla wątków, **bez ograniczeń**

Dodatek: jak sprawdzić wersję biblioteki MPI



- Operacje typu „sparse-collectives” dostępne są od wersji MPI-3
- Aby sprawdzić dostępną wersję (którą wersję standardu używana biblioteka MPI spełnia) można użyć:
 - Funkcji **MPI_Get_version**

C:

```
int MPI_Get_version(int *version, int *subversion)
```

Fortran:

```
CALL MPI_GET_VERSION(INTEGER VERSION, INTEGER SUBVERSION, INTEGER IERROR)
```

```
const int ver = MPI_VERSION;
```

MPI-2 oraz MPI-3 – przegląd




- Funkcjonalności MPI-2
 - Dynamiczne tworzenie i zarządzanie procesami
 - Komunikacja jednostronna
 - RMA (Remote Memory Access)
 - MPI_Put, MPI_Get do zdalnego dostępu do pamięci innego procesu
 - MPI I/O
 - Równoległy dostęp do plików
 - Integracja procesów MPI i wątków (w szczególności OpenMP)
- Funkcjonalności MPI-3
 - Nieblokująca komunikacja grupowa
 - Komunikacja grupowa z sąsiadami
 - Rozszerzona komunikacja jednostronna, m.in. o obsługę pamięci współdzielonej

Wstęp: przekazywanie komunikatów a komunikacja jednostronna



- Przekazywanie komunikatów (message passing)
 - Komunikacja dwustronna – pomiędzy parami procesów
 - Nadawca i odbiorca są jawnie zaangażowani w komunikację
 - Podstawowe operacje: Send, Recv, Sendrecv
 - Tryby przesyłania blokujące i nieblokujące (+ synchronizacja)
- Komunikacja jednostronna (remote memory access)
 - Komunikacja jednostronna – tylko jeden proces aktywnie uczestniczy
 - Procesy komunikują się poprzez zdalny dostęp do pamięci
 - Zdalny proces udostępnia pamięć, proces lokalny wykonuje transfer danych
 - Podstawowe operacje: Put, Get
 - Różne tryby zależnie od zaangażowanie procesu zdalnego (target)
 - Różne mechanizmy synchronizacji

Wstęp: komunikacja jednostronna



RMA : model pamięci



- Okno (**window**) to nazwa obszaru w lokalnej pamięci procesu, który podlega operacjom zdalnego dostępu (RMA)
- Zakres dostępu do pamięci zdalnego procesu obejmuje jedynie dane znajdujące się w utworzonych oknach
- Okna tworzy proces (lokalny), który jest właścicielem danych (obszaru pamięci)

Okna pamięci dla RMA

- Okno to obszar w lokalnej pamięci procesu, do którego mogą mieć dostęp inne procesy
- Inne procesy wykonują operacje na pamięci przypisanej do okna (Put, Get lub Accumulate)
- Okno jest obiektem udostępnianym dla grupy procesów należących do danego komunikatora

Tworzenie okien

- Utworzenie okna poprzez przypięcie wcześniej zalokowanego bufora (buffer)

```
MPI_Win_create(buffer, buffer_size, disp_unit, info,  
MPI_COMM_WORLD, &win)
```

- Operacja kolektywna w grupie procesów (tutaj `MPI_COMM_WORLD`)

- Zniszczenie okna

```
MPI_Win_free(&win)
```

C:

```
int MPI_win_create ( void *base, MPI_Aint size, int disp_unit,  
MPI_Info info, MPI_Comm comm, MPI_Win *win);  
int MPI_Win_free ( MPI_Win *win );
```

- Parametr `disp_unit` (displacement) to rozmiar elementów bufora – rozmiar typu (w bajtach) lub 1 dla manipulacji pojedynczymi bajtami

Przesyłanie danych (Put, Get)



- Operacja **Put** wpisuje dane do zdalnego bufora
- Opis przesyłanych danych jest analogiczny jak w przypadku operacji Send (przesyłanie komunikatów)
- Nazewnictwo:
 - origin – lokalny proces inicjujący operacje RMA (Put, Get)
 - target – zdalny proces udostępniający swoją pamięć
- Operacja **Get** transferuje dane w odwrotnym kierunku – z pamięci procesu *target* do procesu *origin*

C:

```
int MPI_Put (const void *origin_addr, int origin_count, MPI_Datatype  
origin_type, int target_rank, MPI_Aint target_disp, int target_count,  
MPI_Datatype target_type, MPI_Win win);
```

```
int MPI_Get (const void *origin_addr, int origin_count, MPI_Datatype  
origin_type, int target_rank, MPI_Aint target_disp, int target_count,  
MPI_Datatype target_type, MPI_Win win);
```

Operacja Accumulate



- Operacja podobna do PUT, gdzie dane nie są nadpisywane w oknie procesu target tylko akumulowane (operacja redukcji)

C:

```
int MPI_Accumulate(const void *origin_addr, int origin_count,  
MPI_Datatype origin_datatype, int target_rank, MPI_Aint target_disp,  
int target_count, MPI_Datatype target_datatype, MPI_Op op, MPI_Win  
win)
```

- Zestaw operacji MPI_Op analogiczny jak w przypadku MPI_Reduce

Adresacja buforów RMA



- Przesunięcie względem adresu początkowego bufora zdalnego (`target_disp`) jest parametrem operacji Put i Get
- Jednostką przesunięcia nie są bajty tylko `displacement_unit` zdefiniowane przy tworzeniu odpowiedniego okna (`MPI_Win_create`)

- Dwa rodzaje komunikacji RMA w MPI:
 - **active target**: obydwa procesy wymieniające się danymi uczestniczą aktywnie, proces *origin* steruje przepływem danych, proces *target* uczestniczy jedynie w synchronizacji
 - **passive target**: jedynie proces origin jest jawnie zaangażowany w komunikację
- Dostępne trzy mechanizmy synchronizacyjne:
 - FENCE (bariera), POST-START-COMPLETE-WAIT
 - LOCK (zamek)

Synchronizacja pamięci zdalnej - Fence



- Najprostsza forma synchronizacja okna – bariera RMA (*active target*):
`MPI_Win_fence(0, win)`
- Działa podobnie jak `MPI_Barrier` w przypadku trybu przesyłania komunikatów
- Powoduje zakończenie wszystkich transferów RMA rozpoczętych na danym oknie (`win`) od momentu poprzedniego wywołania operacji *Fence*
- Operacja kolektywna wywoływana przez wszystkie procesy używające danego okna
- Podstawowe użycie – przełączanie trybu dostępu do okna: lokalny (zapis do pamięci) i zdalny (operacje Put i Accumulate)
- Parametr `assert` identyfikuje daną barierę dla MPI, może być równy 0

C:

```
int MPI_Win_fence (int assert, MPI_Win win);
```


Synchronizacja pamięci zdalnej - PSCW



- Mniej restrykcyjna forma synchronizacji pozwalająca na ograniczenie tylko do par komunikujących się procesów (active target)
- Proces *target* udostępnia okno grupie procesów wywołaniem **POST** i zamyka dostęp wywołaniem **WAIT**
- Proces *origin* rozpoczyna dostęp do okna od wywołania **START** i kończy wywołaniem **COMPLETE**

Synchronizacja pamięci zdalnej – Lock

- Zapewnia wyłączość* na dostęp do okna pamięci dla danego procesu o numerze **rank** (proces *origin*)
- Proces *target* nie jest zaangażowany (passive target)

C:

```
int MPI_Win_lock(int lock_type, int rank, int assert, MPI_Win win);
```

- Odblokowanie i synchronizacja okna poprzez zwolnienie zamka

C:

```
int MPI_Win_unlock(int rank, MPI_Win win);
```

- Zamki typu `MPI_LOCK_SHARED` pozwalają na grupowy (nie kolektywny) dostęp poprzez funkcje `MPI_Win_lock_all` i `MPI_Win_unlock_all`

Tworzenie okien (2)

- Dwa dodatkowe tryby tworzenia okien dla operacji RMA:
 - Okno z alokacją pamięci

C:

```
int MPI_Win_allocate(MPI_Aint size, int disp_unit, MPI_Info info,  
MPI_Comm comm, void *baseptr, MPI_Win *win);
```

- Okno z dynamicznie przypinaną pamięcią

C:

```
int MPI_Win_create_dynamic(MPI_Info info, MPI_Comm comm, MPI_Win *win)  
  
int MPI_Win_attach(MPI_Win win, void *base, MPI_Aint size);  
int MPI_Win_detach(MPI_Win win, const void *base)
```

- **Uwaga** w przypadku okien z pamięcią przypinaną dynamicznie, argument **target_disp** w operacjach na tym oknie jest adresem względnym (należy go wcześniej przekazać do procesu *origin*)

Obiekty typu `MPI_Info`

- Pusty obiekt typu `MPI_Info` tworzy funkcja:
 - `MPI_Info_create( info)`
- Dodawanie zawartość klucz-wartość obiektu:
 - `MPI_Info_set(info, key, value)`
- Usuwanie zawartości klucz-wartość:
 - `MPI_Info_delete(info, key)`
- Dodatkowo do zarządzanie obiektami typu `MPI_Info` służą funkcje:
 - `MPI_Info_dup` – duplikuje obiekt
 - `MPI_Info_free` – zwalnia obiekt
 - `MPI_Info_get` – zwraca wartość odpowiadająca kluczowi
 - `MPI_Info_get_nkeys` – zwraca liczbę zdefiniowanych kluczy
- Obiekty tego typu używa się np. przy tworzeniu okien dla transferów RMA

Podsumowanie



- **Omówione zagadnienia**

- MPI jako narzędzie tworzenia zrównoleglonych programów
- Podstawy użycia, tworzenia prostych programów z wykorzystaniem
 - Komunikacji point-to-point blokującej i nieblokującej
 - Komunikacji grupowej (kolektywnej)
 - Wirtualnych topologii
- Typy danych w MPI i podstawowe użycie
- MPI i programowanie w modelu RMA
- Podstawy użycia, tworzenia programów z wykorzystaniem
 - Operacji PUT i GET
 - Różnych trybów synchronizacji
- Materiał obejmował tylko podstawową funkcjonalność MPI-1 i MPI-2
- Kilka przykładów nowości z MPI-3
- Zadania pozwalające na pierwsze kroki w zrównoleglaniu własnych programów

- **Nieomówione zagadnienia**

- Komunikacja point-to-point
 - MPI_Sendrecv i MPI_Sendrecv_replace
 - MPI_Iprobe, MPI_Request_free, MPI_Cancel
- Komunikacja grupowa
 - MPI_Alltoall, MPI_Scan i MPI_Exscan
 - MPI_Gatherv, Scatterv, Allgatherv, Alltoallv, Alltoall
- Wirtualne topologie
 - MPI_Dims_create, MPI_Graph_neighbors, MPI_Graph_neighbors_count
 - MPI_Dist_graph_create_adjacent, MPI_Dist_graph_neighbors
- Stałe specjalne MPI i predefiniowane zmienne, zmienne środowiskowe
- Współpraca z wątkami
 - MPI_Is_thread_main, MPI_Query_thread
- MPI IO dla równoległych operacji na plikach

Zasoby HPC dla nauki



- Zasoby ICM UW

- Okeanos
- Topola
- Rysy (GPU)



- EuroHPC.pl

- <https://www.eurohpc.pl>



- EuroHPC JU

- LUMI
- <https://lumi-supercomputer.eu/>



EuroHPC
Joint Undertaking



Ćwiczenia

Zadania

Propozycje ćwiczeń

- Hello - komunikator i przesyłanie komunikatów
- Kwadratura - komunikacja kolektywna
- Ping-pong (samodzielnie)


Zadanie 1

POWITANIE

`hello/hello0.c`

Pobieranie informacji z komunikatora

Zadanie: każdy proces wypisuje swój identyfikator systemowy (PID) numer (rank) oraz liczbę wszystkich procesów w domyślnym komunikatorze



Pliki nagłówkowe

Pliki nagłówkowe

C:

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

Fortran 90:

```
use mpi
```

Fortran 77:

```
include 'mpif.h'
```

Podstawy: kompilacja i uruchomienie



- Ustawienie sesji (SLURM) i środowiska

```
>> srun -n 4 -reservation=computing --pty --time 15 bash -l  
>> module load common/mpi/openmpi/4.0.5
```

- Kompilacja

```
>> mpicc hello0.c
```

- Uruchomienie

```
>> mpiexec ./a.out
```


Zadanie 2

POWITANIE (WERSJA 2)

`hello/hello1.c`

Pierwszy program z komunikacją

Zadanie: wyróżniony proces (0) odbiera i wypisuje komunikaty wysyłane przez pozostałe procesy (1,2,...,n) w ramach komunikatora



Powitanie: pliki nagłówkowe



Pliki nagłówkowe

C:

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

Fortran 90:

```
use mpi
```

Fortran 77:

```
include 'mpif.h'
```

Powitanie: inicjalizacja MPI

Wspólna część programu

C:

```
int main(int argc, char** argv) {  
  
    int numranks, src, dest, myrank;  
    int tag = 1;  
    char mes[50];  
    MPI_Status status;  
  
    MPI_Init(&argc, &argv);  
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);  
    MPI_Comm_size(MPI_COMM_WORLD, &numranks);  
    ...  
  
    MPI_Finalize();  
  
    return 0;  
}
```


Powitanie: proces 0

Część programu wykonywana przez proces odbierający (0)

C:

```
for (src = 1; src < numranks; src++) {  
  
    MPI_Recv(mes, 50, MPI_CHAR, src, tag, \  
  
    MPI_COMM_WORLD, &status);  
  
    printf("%s\n", mes);  
}
```

Powitanie: pozostałe procesy 1,..., n-1



Część programu wykonywana przez pozostałe procesy

C:

```
sprintf(mes, "Halo, tu proces %d", myrank);  
  
dest = 0;  
  
MPI_Send(mes, strlen(mes) + 1, MPI_CHAR, dest, tag, \  
  
MPI_COMM_WORLD);
```

Powitanie: kompletny program



```
int main(int argc, char** argv) {

    int numranks, src, dest, myrank;
    int tag = 1;
    char mes[50];
    MPI_Status status;

    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
    MPI_Comm_size(MPI_COMM_WORLD, &numranks);

    if ( myrank != 0 ) {
        sprintf(mes, "Halo, tu proces %d", myrank);
        dest = 0;
        MPI_Send(mes, strlen(mes) + 1, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
    } else {
        for (src = 1; src < numranks; src++) {
            MPI_Recv(mes, 50, MPI_CHAR, src, tag, MPI_COMM_WORLD, &status);
            printf("%s\n", mes);
        }
    }

    MPI_Finalize();
    return 0;
}
```

Uruchomienie w systemie kolejkowym



- Definicja zadania dla systemu kolejkowego (skrypt kolejowy SLURM)

```
hello.sl:
#!/bin/bash -l
#SBATCH --time=00:10:0
#SBATCH --nodes=1
#SBATCH --ntasks-per-node 4
#SBATCH --job-name="hello_mpi"
#SBATCH --output="hello.out"
#SBATCH --error="hello.err"

module load common/mpi/mpich
srun ./a.out
```

```
>> sbatch --account=[...] --reservation=[...] hello.sl
```

Powitanie: kolejność komunikatów




- Załóżmy, że zamiast
- odbierać komunikaty od procesów o numerach 1,...,numranks-1 kolejno
- odbieramy od dowolnego procesu, który w danym momencie nadaje komunikat:

C:

```
for (src = 1; src < numranks; src++) {  
  
    MPI_Recv(mes, 50, MPI_CHAR, MPI_ANY_SOURCE, tag, \  
  
    MPI_COMM_WORLD, &status);  
  
    printf("%s\n", mes);  
}
```

Powitanie: podsumowanie

- Wprowadź zmianę z poprzedniego slajdu i uruchom program kilkakrotnie
 - Co można zaobserwować?
 - Dlaczego tak się dzieje?



Zadanie 3


KWADRATURA PROSTOKĄTÓW

`pi/pi.c`

Prosta kwadratura (całka numeryczna)



- Całkowanie metodą prostokątów następującego wzoru:



$$\Pi = 4 \int_0^1 \frac{1}{1+x^2} \approx \sum_{i=0}^n \frac{1}{1 + \left(\frac{i+0.5}{n}\right)^2} \cdot h$$



$$f(x) = \frac{1}{1+x^2}$$

Zadanie 4

PING_PONG

Program ping pong

- Zadanie:** dwa procesy komunikują się naprzemiennie. Pierwszy proces (0) wysyła wiadomość (np. liczbę 1) do drugiego procesu (1). Następnie wiadomość jest odsyłana z powrotem. Schemat powtarzamy kilkakrotnie.



Program ping pong (2)

- Użyj trybu MPI_Ssend

C:

```
MPI_Ssend(&snd_buf, 1, MPI_INT, dest, ping_tag, \
          MPI_COMM_WORLD);

MPI_Recv(&rcv_buf, 1, MPI_INT, source, pong_tag, \
         MPI_COMM_WORLD, &stat);
```