

Προηγμένες αρχιτεκτονικές υπολογιστών και προγραμματισμός παραλλήλων συστημάτων

LAB-06. MPI (Μέρος Γ') – Οι
βασικές συναρτήσεις του MPI

Οι 6 βασικές συναρτήσεις του MPI

- Το MPI περιλαμβάνει 125 συναρτήσεις.
- Παρόλα αυτά 6 μόνο συναρτήσεις αρκούν για να υλοποιηθούν τα περισσότερα προγράμματα:
 - `MPI_Init`
 - `MPI_Finalize`
 - `MPI_Comm_size`
 - `MPI_Comm_rank`
 - `MPI_Send`
 - `MPI_Recv`

MPI_Init

- Εκκινεί το περιβάλλον εκτέλεσης του MPI.
- Μπορεί να κληθεί μόνο από το κυρίως thread.
- Αυτό θα είναι και το thread που θα καλέσει την `MPI_Finalize()`.
- Δέχεται δύο ορίσματα:
 - `argc`: Pointer προς το πλήθος των ορισμάτων της εφαρμογής.
 - `argv`: Pointer προς τον πίνακα ορισμάτων της εφαρμογής.
 - Μπορεί να περαστεί `NULL` και για τα δύο.

MPI_Finalize

- Τερματίζει το περιβάλλον εκτέλεσης του MPI.
- Δεν δέχεται ορίσματα.
- Πρέπει να καλείται από το κυρίως thread όλων των διεργασιών του MPI.
- Μετά την κλήση της, ο αριθμός των διεργασιών που εκτελούνται είναι απροσδιόριστος.
- Δεν συστήνεται η διενέργεια εργασιών μετά την κλήση της.

MPI_Comm_size

- Καθορίζει το μέγεθος μιας ομάδας διεργασιών που σχετίζεται με ένα communicator.
- Δέχεται δύο ορίσματα:
 - `comm`: ένας pointer προς τον communicator (αντικείμενο τύπου `MPI_comm`).
 - `size`: το μέγεθος της ομάδας (ακέραιος pointer – `int *size`).
- Είναι thread-safe: Μπορεί να κληθεί με ασφάλεια από πολλαπλά threads.

MPI_Comm_rank

- Καθορίζει την τάξη της διεργασίας που εκτελείται μέσα στην ομάδα ενός communicator.
- Δέχεται δύο ορίσματα:
 - `comm`: ένας `pointer` προς τον communicator (αντικείμενο τύπου `MPI_comm`).
 - `rank`: τάξη της ομάδας μέσα στην ομάδα του `comm` (ακέραιος `pointer – int *rank`).
- Είναι `thread-safe`: Μπορεί να κληθεί με ασφάλεια από πολλαπλά threads.

Ένα απλό πρόγραμμα

- Όλες οι μη-MPI ρουτίνες εκτελούνται τοπικά σε κάθε διεργασία. Έτσι, πχ, το `printf` εκτελείται σε κάθε διεργασία.

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

int main (int argc, char **argv) {
    int rank, size;
    MPI_Init (&argc, &argv);
    MPI_Comm_rank (MPI_COMM_WORLD, &rank);
    MPI_Comm_size (MPI_COMM_WORLD, &size);
    printf ("Hello world! I'm %d of %d\n", rank, size);
    MPI_Finalize ();
    return 0;
}
```

Πέρασμα μηνυμάτων

- Αποστολή μηνύματος point-to-point:
 - `send(dest, type, address, length)`
 - `dest`: ένας ακέραιος που αναπαριστά τη διεργασία (rank) που θα λάβει το μήνυμα.
 - `type`: ένας θετικός ακέραιος τον οποίο ο παραλήπτης μπορεί να χρησιμοποιήσει για να επιλέξει μηνύματα.
 - `(address, length)` περιγράφει ένα ενιαίο χώρο στη μνήμη που περιέχει το μήνυμα προς αποστολή.
- Αποστολή μηνύματος προς όλους (global):
 - `broadcast(type, address, length)`

Buffer

- Η αποστολή και η λήψη μόνο μιας συνεχούς σειράς από bytes έχει μειονεκτήματα:
- Κρύβεται από το hardware η πραγματική δομή των δεδομένων.
- Απαιτείται πακετάρισμα διάσπαρτων δεδομένων.
 - Π.χ. γραμμές πίνακα αποθηκευμένου κατά στήλες.
 - Συλλογές διαφορετικών τύπων δομών δεδομένων.
- Εμποδίζει την επικοινωνία μεταξύ μηχανών με διαφορετικές αναπαραστάσεις των τύπων των δεδομένων (πχ το μήκος ή το alignment ενός `int`, ενός `double`, κλπ).


MPI Buffer

- Στο MPI ο buffer ορίζεται από starting address, datatype, και count.
- Datatype =
 - elementary (όλοι τα primitive datatypes της C ή Fortran).
 - πίνακας από datatypes.
 - Blocks από datatypes.
 - Δεικτοδοτημένο (indexed) array με blocks από datatypes.
 - Γενική δομή.
- Τα Datatypes δημιουργούνται αναδρομικά.
- Οι ορισμοί των βασικών datatypes επιτρέπουν ετερογενή επικοινωνία.


Τύποι δεδομένων

- Ο απλός τύπος είναι πολύ περιοριστικός.
- Συχνά χρησιμοποιούμε overloading για να επιτύχουμε την απαραίτητη ευελιξία.
- Προβλήματα:
 - κάτω από τον έλεγχο του χρήστη.
 - επιτρέπονται wildcards (MPI_ANY_TAG).
 - συγκρούσεις χρήσης της βιβλιοθήκης με άλλους χρήστες ή άλλες βιβλιοθήκες.


Ορθή επικοινωνία




Εσφαλμένη επικοινωνία



Επικοινωνία με αναμονή



Εσφαλμένη επικοινωνία με αναμονή



Λύση στο πρόβλημα του τύπου

- Διαφορετικό context επικοινωνίας για κάθε οικογένεια μηνυμάτων. Χρησιμοποιείται για την τοποθέτηση μηνυμάτων στην ουρά (queueing) και το ταίριασμα (matching) των send και receive.
- Απαγόρευση wildcards, για ασφάλεια.
- Οι τύποι (tags, στο MPI) διατηρούνται για κανονική χρήση (wildcards OK).

Περιορισμοί στην επικοινωνία

- Ξεχωριστά γκρουπ διεργασιών δουλεύουν σε ξεχωριστά υπο-προβλήματα.
- Επιθυμητές οι τοπικές μεταβλητές στις διεργασίες.
- Ο κοινός χώρος διευθύνσεων δυσκολεύει το modularity.
- Τα μηνύματα της εφαρμογής διαχωρίζονται από τα εσωτερικά μηνύματα της βιβλιοθήκης.
- Η γνώση των τύπων μηνυμάτων της βιβλιοθήκης είναι ανεπιθύμητη.
- Ο συγχρονισμός πριν και μετά από τις κλήσεις στις συναρτήσεις βιβλιοθήκης είναι ανεπιθύμητος.

MPI_Send

- Η βασική συνάρτηση αποστολής μηνυμάτων.
- **`int MPI_Send(const void *buf, int count, MPI_Datatype dt, int dst, int tag, MPI_Comm comm)`**
 - `buf`: αρχική διεύθυνση του buffer που θα σταλεί.
 - `count`: πλήθος στοιχείων στον buffer.
 - `dt`: ο τύπος δεδομένων κάθε στοιχείου στον buffer.
 - `dst`: η τάξη (rank) της διεργασίας που θα λάβει τα δεδομένα.
 - `tag`: ακέραια ετικέτα μηνύματος.
 - `comm`: ο communicator.

MPI_Send (2)

- Επιστρέφεται `MPI_SUCCESS` αν η αποστολή ήταν επιτυχής, ή ακέραιος κωδικός σφάλματος.
- Η `MPI_Send` είναι blocking συνάρτηση.
- Η διεργασία θα μπλοκαριστεί μέχρι να ολοκληρωθεί η αποστολή (και η λήψη από την άλλη πλευρά).
- Είναι thread-safe: Μπορεί να κληθεί με ασφάλεια από πολλαπλά threads.

MPI_Recv

- Η βασική συνάρτηση παραλαβής μηνυμάτων:
- **int MPI_Recv(void * buf, int count, MPI_Datatype dt, int source, int tag, MPI_Comm comm, MPI_Status * status)**
 - **buf**: αρχική διεύθυνση του buffer που θα ληφθεί.
 - **count**: το *μέγιστο* πλήθος στοιχείων που θα ληφθούν.
 - Το πραγματικό πλήθος στοιχείων λαμβάνεται με την `MPI_Get_count`.
 - **dt**: ο τύπος δεδομένων κάθε στοιχείου στον buffer.
 - **source**: η τάξη (rank) της διεργασίας που έστειλε τα δεδομένα.
 - **tag**: ακέραια ετικέτα μηνύματος.
 - **comm**: ο communicator.
 - **status**: αντικείμενο κατάστασης.

MPI_Recv (2)

- Επιστρέφεται `MPI_SUCCESS` αν η λήψη ήταν επιτυχής, ή ακέραιος κωδικός σφάλματος.
- Η `MPI_Recv` είναι blocking συνάρτηση.
- Η διεργασία θα μπλοκαριστεί μέχρι να ολοκληρωθεί η λήψη των δεδομένων.
- Είναι thread-safe: Μπορεί να κληθεί με ασφάλεια από πολλαπλά threads.

MPI Message Tags (1)

- Τα tags μηνυμάτων είναι προαιρετικά.
- Μπορούν να λάβουν αυθαίρετες ακέραιες τιμές που φανερώνουν τη σημασιολογία των μηνυμάτων.
- Προσθέτουν πληροφορία σχετικά με τη φύση του μηνύματος.
- Σε περίπτωση που δύο διεργασίες P_0 και P_1 ανταλλάσσουν συχνά μηνύματα πολλαπλών τύπων, τα tags μπορούν να διαφοροποιήσουν τη φύση αυτών των μηνυμάτων.
- Διευκολύνεται έτσι η επεξεργασία στη λήψη.
 - Παράδειγμα: Αποστολή δύο διανυσμάτων από την P_0 στην P_1 .
 - tag=1: Η P_1 πρέπει να προσθέσει τα διανύσματα.
 - tag=2: Η P_1 πρέπει να υπολογίσει το εσωτερικό τους γινόμενο.
 - tag=3: Η P_1 πρέπει να υπολογίσει το εξωτερικό τους γινόμενο.

MPI Message Tags (2)

- Γίνεται ταίριασμα των tags κατά τη λήψη.
- Μπορεί όμως να χρησιμοποιηθεί ως tag το wildcard `MPI_ANY_TAG`: Τότε ο παραλήπτης θα ταιριάζει αυθαίρετα tags.
- Ο παραλήπτης μπορεί να μάθε το tag που έβαλε σε ένα μήνυμα ο αποστολέας μέσω της συνάρτησης `MPI_Probe()`.

Η δομή MPI_Status

- Περιέχει πληροφορία για την κατάσταση του παραληφθέντος μηνύματος.

```
struct MPI_Struct {  
    int MPI_SOURCE;  
    int MPI_TAG;  
    int MPI_ERROR;  
    int cancelled;  
    size_t count;  
} MPI_Status;
```

- MPI_Source: Ο αποστολέας του μηνύματος.
- MPI_TAG: Το tag του μηνύματος.
- MPI_ERROR: Κωδικός σφάλματος σχετικός με το μήνυμα.
- cancelled: Ένδειξη ακύρωσης της αίτησης ή όχι.
- count: Πλήθος οντοτήτων που παρελήφθησαν.

Συλλογική επικοινωνία: MPI_Bcast

- Αποστολή μηνυμάτων από την διεργασία με τάξη `root` προς όλες τις άλλες διεργασίες του `comm`.
- **`int MPI_Bcast(void *buffer, int count, MPI_Datatype dt, int root, MPI_Comm comm)`**
 - `buf`: αρχική διεύθυνση του `buffer`.
 - `count`: πλήθος στοιχείων στον `buffer`.
 - `dt`: ο τύπος δεδομένων κάθε στοιχείου στον `buffer`.
 - `root`: η τάξη (`rank`) της διεργασίας που πραγματοποιεί την αποστολή.
 - `comm`: ο `communicator`.

Συλλογική επικοινωνία: MPI_Reduce

- Συνδυάζει δεδομένα από όλες τις διεργασίες και επιστρέφει το αποτέλεσμα σε μια μόνο διεργασία.
- **int MPI_Reduce(const void *sendbuf, void *recvbuf, int count, MPI_Datatype dt, MPI_Op op, int root, MPI_Comm comm)**
 - **sendbuf**: αρχική διεύθυνση του buffer που θα σταλεί.
 - **recvbuf**: αρχική διεύθυνση του buffer που θα παραληφθεί από τη διεργασία με τάξη **root**.
 - **count**: πλήθος στοιχείων στον buffer αποστολής.
 - **dt**: ο τύπος δεδομένων κάθε στοιχείου στον buffer.
 - **op**: η πράξη επί των δεδομένων.
 - **root**: η τάξη της διεργασίας που θα λάβει το αποτέλεσμα της εκτέλεσης της **op**.
 - **comm**: ο communicator.

Αλγόριθμος υπολογισμού π

- Υπάρχουν δεκάδες μέθοδοι στην επίσημη βιβλιογραφία για τον υπολογισμό του π .
- Μία εξ' αυτών:

$$\pi = \frac{1}{n} \sum_{i=1}^n \frac{4}{1 + x_i^2}$$

- Όπου:
- n : η επιθυμητή ακρίβεια (το πλήθος των δεκαδικών ψηφίων του π).

$$x_i = \frac{2i - 1}{2n} = \frac{i - 0.5}{n}$$

Υπολογισμός του π με το MPI (1)

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

int main (int argc, char ** argv) {
    int done = 0, n, myid, numprocs, i, rc;
    double PI25DT = 3.141592653589793238462643;
    double mypi, pi, h, sum, x, a;

    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &numprocs);
    MPI_Comm_rank(MPI_COMM_WORLD, &myid);

    while (!done) {
        // Embed the code of next slide
    }
    MPI_Finalize();
}
```

Υπολογισμός του π με το MPI (2)

```
if (myid == 0) {  
    printf("Enter number of intervals: (0 quits)"); scanf("%d",&n);  
}  
MPI_Bcast(&n, 1, MPI_INT, 0, MPI_COMM_WORLD);  
if (n == 0) { break; }  
  
h = 1.0 / (double) n;  
sum = 0.0;  
  
for (i = myid + 1; i <= n; i += numprocs) {  
    x = h * ((double)i - 0.5);  
    sum += 4.0 / (1.0 + x * x);  
}  
mypi = h * sum;  
MPI_Reduce(&mypi, &pi, 1, MPI_DOUBLE, MPI_SUM, 0, MPI_COMM_WORLD);  
if (myid == 0) {  
    printf("pi is about %.16f, Error=%.16f\n", pi, fabs(pi-PI25DT));  
}
```

Ανάθεση υπολογισμών στις διεργασίες

```
for (i = myid + 1; i <= n; i += numprocs) {  
    x = h * ((double)i - 0.5);  
    sum += 4.0 / (1.0 + x * x);  
}
```

Για numprocs = 5:

myid=0	myid=1	myid=2	myid=3	myid=4
i=1	i=2	i=3	i=4	i=5
i=6	i=7	i=8	i=9	i=10
i=11	i=12	i=13	i=14	i=15
i=16	i=17	i=18	i=19	i=20





Συλλογικές επικοινωνίες στο MPI

- Η επικοινωνία γίνεται στο εσωτερικό μιας ομάδας διεργασιών.
- Τα γκρουπ φτιάχνονται χειροκίνητα. Χρήση συναρτήσεων MPI group-manipulation ή ρουτίνες MPI topology-definition.
- Δε χρησιμοποιούνται message tags. Αντ' αυτού γίνεται χρήση διαφορετικών communicators.
- Καμία συλλογική επικοινωνία non-blocking.
- Τρία είδη συλλογικής επικοινωνίας:
 - Συγχρονισμός.
 - Μετακίνηση δεδομένων.
 - Συλλογικές πράξεις.



Συγχρονισμός: MPI_Barrier

- Η συνάρτηση αυτή μπλοκάρει τη διεργασία που την καλεί μέχρι να την καλέσουν όλες οι διεργασίες που ανήκουν στον communicator `comm`.
- `int MPI_Barrier (MPI_Comm comm)`

Τύποι συλλογικής επικοινωνίας



Τύποι συλλογικών υπολογισμών



Συλλογικές συναρτήσεις MPI_*

- Εδώ: * wildcard = αντικαθίσταται από οποιοδήποτε string.

Allgather	Allgatherv	Allreduce
Alltoall	Alltoallv	Bcast
Gather	Gatherv	Reduce
ReducedScatter	Scan	Scatter
Scatterv		

Συλλογικές συναρτήσεις MPI_* (2)

- Οι συναρτήσεις MPI_All* δίνουν δεδομένα σε όλες τις διεργασίες.
- Οι συναρτήσεις MPI_*n επιτρέπουν διαφορετικού μεγέθους δεδομένα.
- Οι συναρτήσεις MPI_Allreduce, MPI_Reduce, MPI_ReduceScatter, και MPI_Scan παίρνουν τόσο built-in όσο και user-defined συναρτήσεις συνδυασμού.

Συλλογικές συναρτήσεις υπολογισμού

MPI Name	Λειτουργία	MPI name	Λειτουργία
MPI_MAX	maximum	MPI_LXOR	Λογικό XOR
MPI_MIN	minimum	MPI_BAND	Bitwise AND
MPI_PROD	γινόμενο	MPI_BOR	Bitwise OR
MPI_SUM	άθροισμα	MPI_BXOR	Bitwise XOR
MPI_LAND	Λογικό AND	MPI_MAXLOC	Max & Θέση
MPI_LOR	Λογικό OR	MPI_MINLOC	Min & Θέση

User-defined συλλογικές πράξεις

- `int MPI_Op_create(MPI_User_function * ufn, int commute, MPI_Op * op)`
 - `ufn(invec, inoutvec, len, datatype)`
 - Η συνάρτηση `ufn` εκτελεί:
for `i` from 0 to `len - 1`
 `inoutvec[i] = invec[i] op inoutvec[i];`
- `int MPI_Op_free(MPI_Op * op)`