


Προηγμένες αρχιτεκτονικές υπολογιστών και προγραμματισμός παραλλήλων συστημάτων

LAB-09. MPI (Μέρος Ε') – Non-
blocking επικοινωνίες


Η χρήση buffer

- Πώς μεταδίδονται τα δεδομένα μετά την send;



Χωρίς buffer

- Δύο επιλογές:
 - Το send δεν επιστρέφει αν δεν παραδοθούν τα δεδομένα.
 - Το send επιστρέφει πριν παραδοθούν τα δεδομένα.
Έλεγχος παράδοσης αργότερα.



Blocking/Non-blocking επικοινωνίες

- Blocking επικοινωνίες: Η διεργασία μπλοκάρεται μέχρι να ολοκληρωθεί η αντίστοιχη λειτουργία.
 - `MPI_Send`: δεν ολοκληρώνεται μέχρι ο buffer να αδειάσει (έτοιμος για να ξαναχρησιμοποιηθεί).
 - `MPI_Recv`: δεν ολοκληρώνεται μέχρι ο buffer να γεμίσει (έτοιμος για να χρησιμοποιηθεί).
- Non-blocking επικοινωνίες:
 - `MPI_Isend`
 - `MPI_Irecv`

Σκοπός non-blocking επικοινωνιών

- Παροχή ενός μηχανισμού εναλλαγής μεταξύ επικοινωνιών και χρήσιμων υπολογισμών.
 - Οι επικοινωνίες και οι υπολογισμοί μπορούν να πραγματοποιούνται ταυτόχρονα.
 - Αποκρύπτονται οι (όποιες) συνέπειες του (όποιου) latency.
- Αποφυγή deadlocks.
- Αποφυγή buffering και memory-to-memory αντιγραφών.
 - Βελτίωση επιδόσεων.

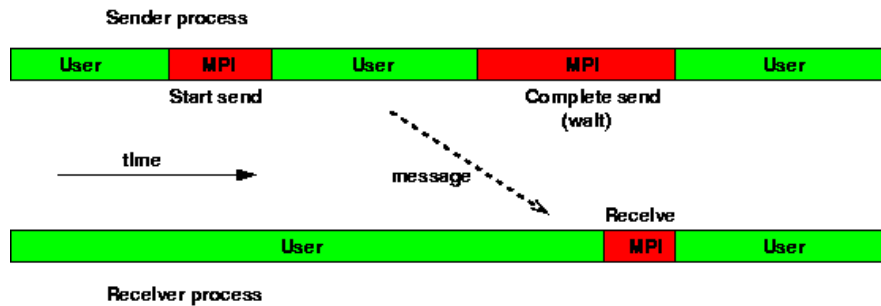

Non-blocking επικοινωνίες

- Non-blocking επικοινωνίες: Η διεργασία δεν μπλοκάρεται μέχρι να ολοκληρωθεί η αντίστοιχη λειτουργία.
- Η εκτέλεση του κώδικα συνεχίζεται κανονικά, χωρίς να έχει ολοκληρωθεί η κληθείσα λειτουργία.
- Οι non-blocking λειτουργίες επιστρέφουν αμέσως ένα αντικείμενο διαχείρισης αίτησης (request handle).
- Μια διεργασία μπορεί να κάνει ερώτηση (query) ή αναμονή (wait) σε ένα request κάνοντας χρήση του αντίστοιχου handle.

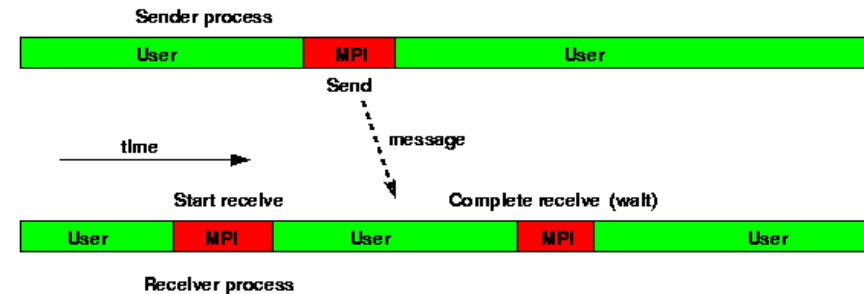

Δομή non-blocking επικοινωνιών (1)

1. Useful work (Program Execution)
2. Non-blocking operation (MPI_Isend, MPI_Irecv,...)
3. Useful work (Program Execution)
4. Complete communication call (MPI_Wait, MPI_Test, ...)
5. Useful work (Program Execution)

Δομή non-blocking επικοινωνιών (2)



Non-blocking send



Non-blocking receive

MPI_Request (Request Handle)

- Αντικείμενο-διαχειριστής non-blocking αιτήσεων.
- Μπορεί να χρησιμοποιηθεί από τις συναρτήσεις `wait` και `test` για ενημέρωση της ολοκλήρωσης της non-blocking λειτουργίας.
 - `MPI_Wait`, `MPI_Waitall`, `MPI_Waitany`,
`MPI_Waitsome`
 - `MPI_Test`, `MPI_Testall`, `MPI_Testany`,
`MPI_Testsome`

MPI_Isend

- Εκκίνηση μιας non-blocking αποστολής μηνύματος.
- **int MPI_Isend(const void *buf, int count, MPI_Datatype dt, int dst, int tag, MPI_Comm comm, MPI_Request *request)**
 - **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.
 - **request (output)**: Ο διαχειριστής του request.

MPI_Irecv

- Εκκίνηση μιας non-blocking λήψης μηνύματος.
- **int MPI_Irecv(void *buf, int count, MPI_Datatype dt, int source, int tag, MPI_Comm comm, MPI_Request * request)**
 - **buf**: αρχική διεύθυνση του buffer που θα ληφθεί.
 - **count**: το πλήθος στοιχείων στον receive buffer.
 - **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.
 - **request (output)**: Ο διαχειριστής του request.

MPI_Wait

- Αναμονή ολοκλήρωσης μιας αίτησης MPI.
- **int MPI_Wait(MPI_Request * request, MPI_Status * status)**
 - **request (input):** Ο διαχειριστής του request.
 - **status (output):** Αντικείμενο κατάστασης της αντίστοιχης λειτουργίας υπό αναμονή.

MPI_Test

- Έλεγχος ολοκλήρωσης μιας αίτησης MPI.
- **int MPI_Test(MPI_Request *request, int *flag, MPI_Status *status)**
 - **request (input):** Ο διαχειριστής του request.
 - **flag (output):** Τίθεται ίση με true αν η αίτηση έχει ολοκληρωθεί.
 - **status (output):** Αντικείμενο κατάστασης της αντίστοιχης λειτουργίας υπό έλεγχο.

Παράδειγμα

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

int main (int argc, char ** argv) {
    /// Number of processes, Rank of current process
    int NumProcs, ProcRank;

    /// Request handle
    MPI_Request request;

    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &NumProcs);
    MPI_Comm_rank(MPI_COMM_WORLD, &ProcRank);

    if (NumProcs != 2) {
        printf("This appl is meant to be run with 2 processes.\n");
        MPI_Abort(MPI_COMM_WORLD, EXIT_FAILURE);
    }
```

```
if (ProcRank == 0) {
    int buffer_sent = 12345;

    printf("Process %d sends value %d.\n", ProcRank, buffer_sent);
    MPI_Isend(&buffer_sent, 1, MPI_INT, 1, 0, MPI_COMM_WORLD, &request);

    printf("Process %d is doing useful work here...\n", ProcRank);
    /// Some useful code here

    MPI_Wait(&request, MPI_STATUS_IGNORE);
} else if (ProcRank == 1) {
    int received;

    printf("Process %d starts receiving data...\n", ProcRank);
    MPI_Irecv(&received, 1, MPI_INT, 0, 0, MPI_COMM_WORLD, &request);

    printf("Process %d is doing useful work here...\n", ProcRank);
    /// Useful code here (received buffer cannot be accessed yet!!)

    MPI_Wait(&request, MPI_STATUS_IGNORE);
    printf("Process %d received value %d.\n", ProcRank, received);
}
```

Πολλαπλές αναμονές

- Είναι συχνά επιθυμητό να περιμένουμε την ολοκλήρωση πολλών request.
- Για παράδειγμα, σε ένα κατανεμημένο περιβάλλον με ύπαρξη master διεργασίας, ο master περιμένει ένα ή περισσότερους slaves να του στείλουν μήνυμα.
- Το MPI διαθέτει συναρτήσεις υποστήριξης τέτοιων πολλαπλών αναμονών.

MPI_Waitall

- Δέχεται πίνακα από request handles και αναμένει την ολοκλήρωση **όλων** των αντίστοιχων λειτουργιών.
- **int MPI_Waitall(int count, MPI_Request requests[], MPI_Status statuses[])**
 - **count**: Πλήθος των λειτουργιών των οποίων την ολοκλήρωση αναμένουμε.
 - **requests[]**: Πίνακας μεγέθους count που περιέχει τους request handles των λειτουργιών υπό αναμονή.
 - **statuses[]**: Πίνακας αντικειμένων status μεγέθους count.

MPI_Waitany

- Δέχεται πίνακα από request handles και αναμένει την ολοκλήρωση **μίας οποιασδήποτε** αντίστοιχης λειτουργίας.
- `int MPI_Waitany(int count, MPI_Request requests[], int *idx, MPI_Status *status)`
 - `count`: Πλήθος των λειτουργιών των οποίων την ολοκλήρωση αναμένουμε.
 - `requests[ ]`: Πίνακας μεγέθους `count` που περιέχει τους request handles των λειτουργιών υπό αναμονή.
 - `idx`: Δείκτης στον πίνακα `requests` που δείχνει ποια λειτουργία ολοκληρώθηκε. Τιμές `[0, count - 1]`.
 - `status`: Αντικείμενο status της λειτουργίας.

MPI_Waitsome

- Δέχεται πίνακα από request handles και αναμένει την ολοκλήρωση **κάποιων** αντίστοιχων λειτουργιών.
- **int MPI_Waitsome(int incount, MPI_Request requests[], int *outcount, int indices[], MPI_Status statuses[])**
 - **incount**: Πλήθος των λειτουργιών των οποίων την ολοκλήρωση αναμένουμε.
 - **requests[]**: Πίνακας μεγέθους **incount** που περιέχει τους request handles των λειτουργιών υπό αναμονή.
 - **outcount**: Πλήθος των λειτουργιών που ολοκληρώθηκαν.
 - **indices[]**: Πίνακας μεγέθους **outcount** με τους δείκτες στον πίνακα **requests** των ολοκληρωμένων λειτουργιών.
 - **statuses[]**: Πίνακας αντικειμένων **status**.

Ταχείες επικοινωνίες

- Η αναμονή λήψης μεγάλου αριθμού μηνυμάτων με blocking τρόπο μπορεί να οδηγήσει στο μπλοκάρισμα μιας διεργασίας για μεγάλο χρονικό διάστημα.
- Ειδικά όταν η μετάδοση γίνεται πάνω σε μη αξιόπιστο δίκτυο.
- Στο παράδειγμα που ακολουθεί, η διεργασία με rank 0 αναμένει μπλοκαρισμένη την παράδοση 100 μηνυμάτων από κάθε άλλη διεργασία.

Παράδειγμα

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

int main (int argc, char ** argv) {
    int rank, size, i, buf[1];
    MPI_Status status;

    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);

    if (rank == 0) {
        for (i = 1; i < size; i++) {
            for (j = 0; j < 100; j++) {
                MPI_Recv(buf, 1, MPI_INT, i, MPI_ANY_TAG, MPI_COMM_WORLD, &status);
                printf("Msg from %d tag %d\n", status.MPI_SOURCE, status.MPI_TAG);
            }
        }
    } else {
        for (i = 0; i < 100; i++)
            MPI_Send (buf, 1, MPI_INT, 0, i, MPI_COMM_WORLD);
    }
    MPI_Finalize();
}
```

Ταχείες επικοινωνίες

- Αν καθυστερήσει η παράδοση ενός μηνύματος, καθυστερεί και η παραλαβή όλων των επόμενων, ακόμα και αν δεν υπάρχει κανένα πρόβλημα.
- Καθυστερέηση.
- Και πολλά επιπλέον προβλήματα:
 - Π.χ. να γεμίσει ο receive buffer και να αρχίσουν να απορρίπονται μηνύματα.
- **Λύση:** άμεση (non-blocking) παραλαβή όσων μηνυμάτων έχουν παραδοθεί.
 - Αναμονή με την `MPI_Waitsome`.

Λύση (Process 0)

```
#define large 128
MPI_Request requests[large];
MPI_Status stats[large];
int indices[large];
int buf[large];

for (i = 1; i < size; i++) {
    MPI_Irecv(buf+i,1,MPI_INT, i, MPI_ANY_TAG, MPI_COMM_WORLD, &requests[i-1]);
}

while (not done) {
    MPI_Waitsome(size - 1, requests, &ndone, indices, stats);
    for (i = 0; i < ndone; i++) {
        j = indices[i];
        printf("Msg from %d, tag %d\n", stats[i].MPI_SOURCE, stats[i].MPI_TAG);
        MPI_Irecv(buf+j,1,MPI_INT,j, MPI_ANY_TAG, MPI_COMM_WORLD, &requests[j]);
    }
}
```

Τρόποι επικοινωνιών

- Το MPI προσφέρει πολλούς τρόπους αποστολής μηνυμάτων:
- Σύγχρονος τρόπος (MPI_Ssend): Το send δεν ολοκληρώνεται μέχρι να εκκινήσει ένα ταιριαστό receive.
- Buffered τρόπος (MPI_Bsend): ο χρήστης ορίζει τον buffer για να χρησιμοποιηθεί από το σύστημα.
- Ready τρόπος (MPI_Rsend): ο χρήστης εγγυάται ότι ένα ταιριαστό receive έχει ήδη εκκινήσει.
 - Επιτρέπει γρήγορα πρωτόκολλα επικοινωνίας
 - Απροσδιόριστη συμπεριφορά αν το receive δεν έχει εκκινήσει
- Non-blocking εκδοχές:
 - MPI_Issend, MPI_Irsend, MPI_Isend
 - Το MPI_Recv λαμβάνει μηνύματα σταλμένα με οποιοδήποτε τρόπο send.

MPI_Ssend, MPI_Issend

- Εκκινεί μία σύγχρονη και blocking αποστολή μηνύματος. Δεν ολοκληρώνεται μέχρι να εκκινήσει ένα ταιριαστό receive.
- **`int MPI_Ssend(const void *buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm)`**
- Non-blocking σύγχρονη αποστολή μηνύματος:
- **`int MPI_Issend(const void *buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm, MPI_Request * request)`**

MPI_Rsend, MPI_Irsend

- Εκκινεί μία ready και blocking αποστολή μηνύματος. Ο χρήστης εγγυάται ότι ένα ταιριαστό receive έχει ήδη εκκινήσει.
- **`int MPI_Rsend(const void *buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm)`**
- Non-blocking ready αποστολή μηνύματος:
- **`int MPI_Irsend(const void *buf, int count, MPI_Datatype datatype, int dest, int tag, MPI_Comm comm, MPI_Request * request)`**

MPI_Bsend (1)

- Εκκινεί μία buffered και blocking αποστολή μηνύματος. Ο χρήστης ορίζει τον buffer για να χρησιμοποιηθεί από το σύστημα.
- **int MPI_Bsend(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_Bsend (2)

- Τοπική εκτέλεση: η ολοκλήρωση της εντολής δεν εξαρτάται από το αν έχει εκδοθεί ένα αντίστοιχο ταιριαστό receive.
- Αν ξεκινήσει ένα Bsend και δεν έχει εκδοθεί αντίστοιχο ταιριαστό receive από τον παραλήπτη η διεργασία πρέπει να βάλει το μήνυμα στον buffer.
- Ο χρήστης ορίζει ο ίδιος χώρο buffer με την MPI_Buffer_attach. Ο χώρος στον buffer δεν είναι διαθέσιμος για επόμενο MPI_Bsend εκτός αν ληφθεί το μήνυμα.
- Ανά πάσα χρονική στιγμή μπορεί να υπάρχει μόνο ένας buffer. Πρέπει να προβλεφθεί να είναι αρκετά μεγάλος ώστε να χωράει το ή τα μηνύματα που δεν έχουν ταιριαστό receive. Σε αντίθετη περίπτωση προκύπτει σφάλμα.

MPI_Bsend (3)

- Ο παρακάτω κώδικας δε δίνει αρκετό χώρο buffer. Χώρος buffer για ένα μόνο send. Το επόμενο MPI_Bsend μπορεί να ξεκινήσει πριν τελειώσει το πρώτο MPI_Bsend τη χρήση του buffer.

```
MPI_Buffer_attach(b, n * sizeof(double) + MPI_BSEND_OVERHEAD);  
for (i=0; i<m; i++) {  
    MPI_Bsend(buf, n, MPI_DOUBLE, ... );  
}
```

Μπορούμε να εξαναγκάσουμε τα μηνύματα να παραδοθούν

```
MPI_Buffer_detach(&b, &n);  
MPI_Buffer_attach(b, n);
```

Η MPI_Buffer_detach δε θα ολοκληρωθεί μέχρι όλα τα buffered μηνύματα να παραδοθούν.