ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΡΗΤΗΣ

ΕΜ 361: Παράλληλοι Υπολογισμοί

Ενότητα #5Β: Message Passing Interface (MPI)

Διδάσκων: Χαρμανδάρης Ευάγγελος
ΤΜΗΜΑ ΕΦΑΡΜΟΣΜΕΝΩΝ ΜΑΘΗΜΑΤΙΚΩΝ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΚΑΙ ΤΕΧΝΟΛΟΓΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

Με τη συγχρηματοδότηση της Ελλάδας και της Ευρωπαϊκής Ένωσης

Άδειες Χρήσης

- Το παρόν εκπαιδευτικό υλικό υπόκειται στην άδεια χρήσης **Creative Commons** και ειδικότερα

Αναφορά – Μη εμπορική Χρήση – Όχι Παράγωγο Έργο 3.0 Ελλάδα

(Attribution – Non Commercial – Non-derivatives 3.0 Greece)

[ή επιλογή ενός άλλου από τους έξι συνδυασμούς]

[και αντικατάσταση λογότυπου άδειας όπου αυτό έχει μπει (σελ. 1, σελ. 2 και τελευταία)]

- Εξαιρείται από την ως άνω άδεια υλικό που περιλαμβάνεται στις διαφάνειες του μαθήματος, και υπόκειται σε άλλου τύπου άδεια χρήσης. Η άδεια χρήσης στην οποία υπόκειται το υλικό αυτό αναφέρεται ρητώς.

Χρηματοδότηση

- Το παρόν εκπαιδευτικό υλικό έχει αναπτυχθεί στα πλαίσια του εκπαιδευτικού έργου του διδάσκοντα.
- Το έργο «**Ανοικτά Ακαδημαϊκά Μαθήματα στο Πανεπιστήμιο Κρήτης**» έχει χρηματοδοτήσει μόνο τη αναδιαμόρφωση του εκπαιδευτικού υλικού.
- Το έργο υλοποιείται στο πλαίσιο του Επιχειρησιακού Προγράμματος «Εκπαίδευση και Δια Βίου Μάθηση» και συγχρηματοδοτείται από την Ευρωπαϊκή Ένωση (Ευρωπαϊκό Κοινωνικό Ταμείο) και από εθνικούς πόρους.

Με τη συγχρηματοδότηση της Ελλάδας και της Ευρωπαϊκής Ένωσης

ΕΜ 361: Παράλληλοι Υπολογισμοί

Χαρμανδάρης Βαγγέλης, Τμήμα Εφαρμοσμένων Μαθηματικών

Πανεπιστήμιο Κρήτης, Χειμερινό Εξάμηνο 2010/11

Κεφάλαιο 5:
(B) Message Passing Interface (MPI)

Message Passing Interface (MPI)

Βασική ιδέα: Ο χρήστης γράφει τον κώδικα (π.χ. σε C ή Fortran) και μετά χρησιμοποιεί τις εντολές της κατάλληλης βιβλιοθήκης για τον παραλληλισμό των διεργασιών.

Θα δούμε πιο αναλυτικά:

- **Τι είναι το MPI; Εισαγωγικά.**
- **Ένα απλό πρόγραμμα σε MPI.**
- **Υποπρογράμματα Διαχείρισης του MPI Παράλληλου Περιβάλλοντος.**
- **Υποπρογράμματα Επικοινωνίας των Διεργασιών.**
- **Τοπολογία**

Τι Είναι το MPI;

• Το MPI είναι μια βιβλιοθήκη υποπρογραμμάτων ανταλλαγής μηνυμάτων και μεταφοράς δεδομένων.

• Χαρακτηριστικά του MPI: Αποτελεσματικότητα, Φορητότητα-Μεταβιβασιμότητα, Ευελιξία.

• Ανεπτυγμένο για πληθώρα (σχεδόν όλα) υπολογιστικών συστημάτων διαφορετικής αρχιτεκτονικής.

• Σχεδιασμένο το για C/C++ όσο και Fortran/ Fortran 90.

• Ιστορία και Εξέλιξη:

➢ 1980 – αρχές 1990: Ανομοιογενές λογισμικό. Προβλήματα μεταφοράς προγραμμάτων. Ανάγκη δημιουργίας διεθνούς προτύπου.

➢ 1992 – 1994: Καθιέρωση του MPI ως διεθνές πρότυπο.

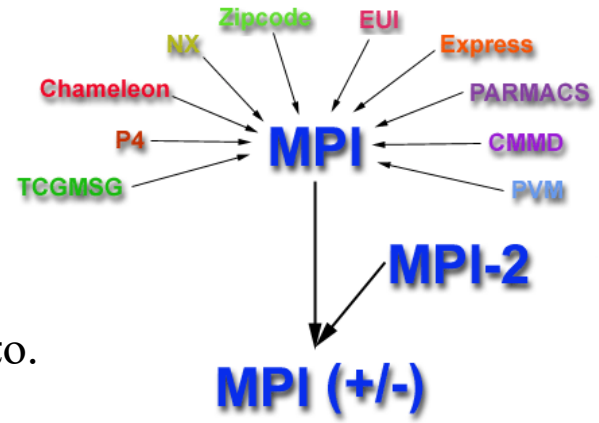

Τι Είναι το MPI;

Λόγοι χρησιμοποίησης του MPI:

• **Διεθνές Πρότυπο:** Το MPI είναι η στάνταρτ βιβλιοθήκη ανταλλαγής μηνυμάτων. Υποστηρίζεται από όλα τα υπολογιστικά συστήματα HPC (High Performance Computing).

• **Διαθεσιμότητα:** Υπάρχουν διάφορες διαθέσιμες υλοποιήσεις (implementations). Το λογισμικό είναι ελεύθερο.

• **Αποτελεσματικότητα:** οι διαφορετικές υλοποιήσεις εκμεταλλεύονται χαρακτηριστικά του hardware με αποτέλεσμα την καλύτερη απόδοση των προγραμμάτων.

• **Φορητότητα:** οι κώδικες μεταφέρονται εύκολα σε διαφορετικά συστήματα.

• **Λειτουργικότητα:** Στο MPI-1 υπάρχουν 128 υποπρογράμματα και στο MPI-2 152.

• Το MPI είναι ανεπτυγμένο για συστήματα κοινής και κατανεμημένης μνήμης.

Γενική Δομή ενός Προγράμματος MPI

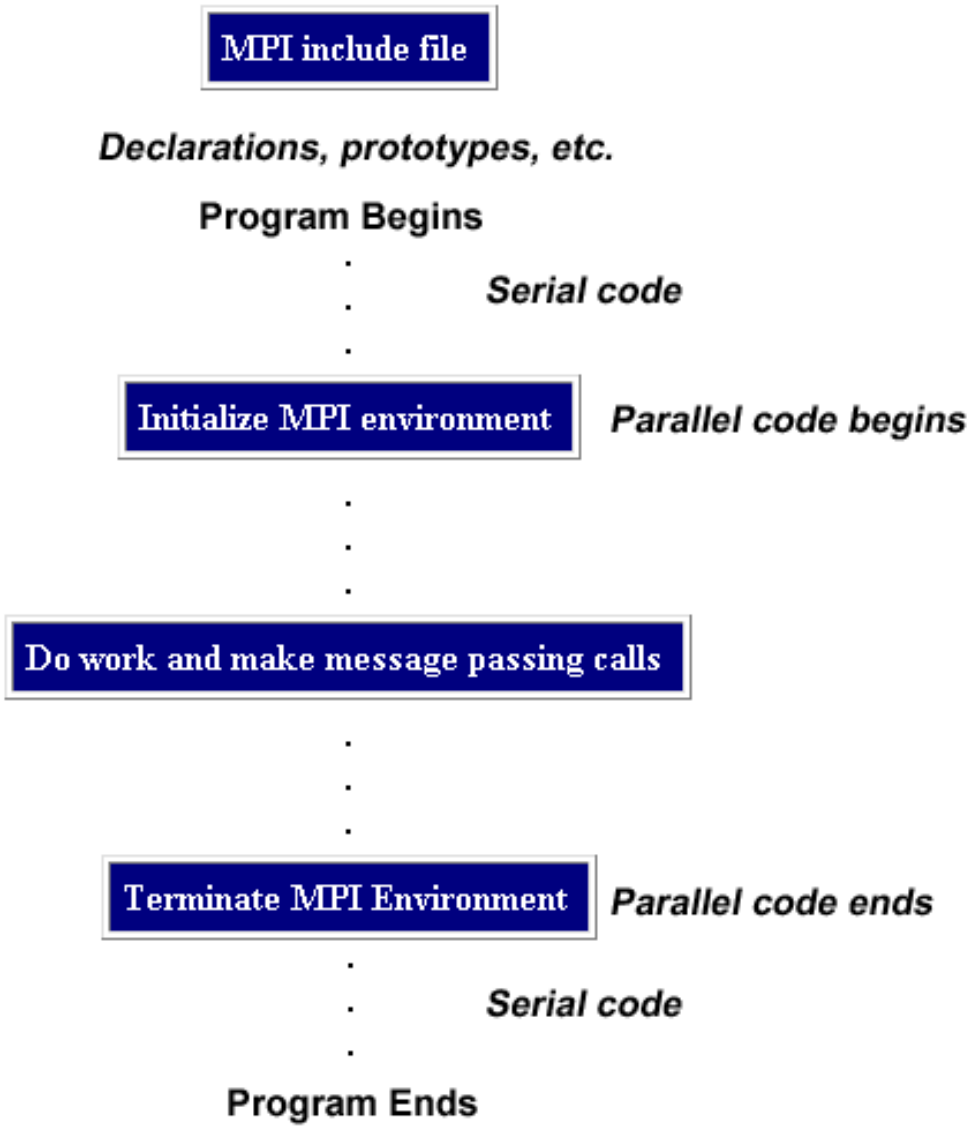

Παράδειγμα: 'Hello world' πρόγραμμα

Απλό πρόγραμμα σε C

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

int main(argc,argv)
{
  int numtasks, rank,

  MPI_Init (&argc,&argv);

  MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
  MPI_Comm_rank(MPI_COMM_WORLD, &rank);

  printf ("Hello world from process %d of %d\n", rank, numtasks);

  MPI_Finalize();
}
```

Παράδειγμα: 'Hello world' πρόγραμμα

Απλό πρόγραμμα σε Fortran

```
program simple

include  'mpif.h'

integer  numtasks, rank, ierr

call MPI_INIT(ierr)

call MPI_COMM_SIZE(MPI_COMM_WORLD, numtasks, ierr)
call MPI_COMM_RANK(MPI_COMM_WORLD, rank, ierr)

print *, 'Hello world from process ', rank, 'of', numtasks

call MPI_FINALIZE(ierr)

stop
end
```

Περιγραφή Απλού Προγράμματος

• Οι εντολές

#include "mpi.h", include 'mpif.h'

απαιτούνται από όλα τα προγράμματα / υπορουτίνες που χρησιμοποιούν MPI καθώς είναι αυτές που παρέχουν πρόσβαση στην βιβλιοθήκη MPI.

Η διάταξη των συναρτήσεων MPI είναι:

• **C/C++:** *MPI_Xxxxx (parameter, …)*

- Παράδειγμα: *MPI_Send (&buf, count, type, dest, comm)*
- Όλες οι συναρτήσεις C του MPI επιστρέφουν δείκτες λαθών (error code) τύπου ακεραίου.

• **Fortran:** *call MPI_XXXX (parameter, …, ierr)*

- Παράδειγμα: *MPI_SEND (buf, count, type, dest, comm, ierr)*
- Τα υποπρογράμματα Fortran επιστρέφουν δείκτες λαθών τύπου ακεραίου ως το τελευταίο όρισμά τους.

• Οι κοινές εντολές του προγράμματος (π.χ. print *, 'Hello world from process ', rank, 'of', numtasks) είναι **τοπικές**, δηλαδή εκτελούνται από κάθε επεξεργαστή.

Περιγραφή Απλού Προγράμματος: Υποπρογράμματα Διαχείρισης

Διαχειριστής Επικοινωνίας (Δ.Ε.) - Communicator: Ένα σύνολο διεργασιών που μπορούν να στείλουν/λάβουν μηνύματα.

• MPI_COMM_WORLD είναι ο προκαθορισμένος Δ.Ε.

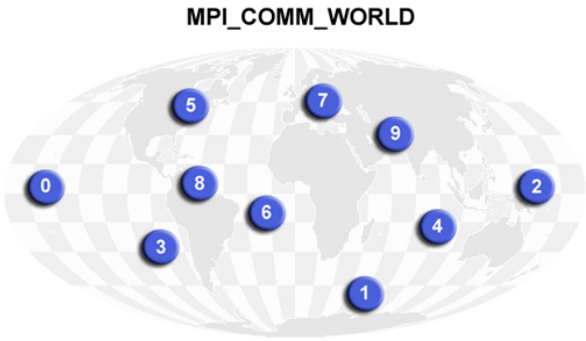

• Συνήθως ο αριθμός των διεργασιών συμπίπτει με τον αριθμό των επεξεργαστών που θέλουμε να χρησιμοποιήσουμε. Οι επεξεργαστές μπορεί να είναι οπουδήποτε.

• **Ταξινόμηση:** Μέσα στον Δ.Ε. κάθε διεργασία αριθμείται με ένα ακέραιο αριθμό (rank) ξεκινώντας από το 0. Δηλαδή *P* διεργασίες αριθμούνται από 0 ως *P*-1.

• Η ταξινόμηση χρησιμοποιείται από τον χρήστη στην επικοινωνία μεταξύ των διεργασιών (π.χ. if rank=0 do something / if rank=1 do something else).

Υποπρογράμματα-Συναρτήσεις Διαχείρισης MPI

- **MPI_Init:** Υποδηλώνει την έναρξη του MPI. Πρέπει να καλείται πριν από οποιαδήποτε άλλη εντολή του MPI.
  C: *MPI_Init (&argc, &argv);*
  Fortran: *call MPI_INIT(ierr)*

- **MPI_Comm_size:** Προσδιορίζει τον αριθμό των διεργασιών-επεξεργαστών που σχετίζονται με τον ΔΕ.
  C: *MPI_Comm_size (comm, &size);*
  Fortran: *call MPI_COMM_SIZE(comm, size, ierr)*

- **MPI_Comm_rank:** Προσδιορίζει τον αριθμό της διεργασίας που καλείται μέσα στον ΔΕ.
  C: *MPI_Comm_rank (comm, &rank);*
  Fortran: *call MPI_COMM_RANK(comm, rank, ierr)*

Υποπρογράμματα Διαχείρισης MPI

- **MPI_Abort:** Τερματίζει όλες τις διεργασίες MPI που σχετίζονται με τον Δ.Ε.
  C: *MPI_Abort (comm, ierr);*
  Fortran: *call MPI_ABORT(comm, ierr)*

- **MPI_Get_processor_name:** Επιστρέφει το όνομα του επεξεργαστή καθώς και το μήκος (αριθμός χαρακτήρων) του ονόματος.
  C: *MPI_Get_processor_name (&name, &namelength);*
  Fortran: *call MPI_GET_PROCESSOR_NAME(name, namelength)*

- **MPI_Wtime:** Επιστρέφει τον χρόνο (wall time clock), σε δευτερόλεπτα ενός επεξεργαστή. Χρησιμοποιείται για μέτρηση του χρόνου εκτέλεσης μιας διεργασίας.
  C: *MPI_Wtime ();*
  Fortran: *call MPI_WTIME()*

- **MPI_Finalize:** Υποδηλώνει τη λήξη χρήσης του MPI. Πρέπει να καλείται στο τέλος.
  C: *MPI_Finalize (&argc, &argv);*
  Fortran: *call MPI_FINALIZE(ierr)*

Υποπρογράμματα Επικοινωνίας MPI

Βασικά στοιχεία:

- Ποιος στέλνει το μήνυμα / που στάλθηκε το μήνυμα.
- Μέγεθος – Τύπος των δεομένων που στάλθηκαν.
- Λήψη του μηνύματος – Αναγνώριση των δεδομένων.

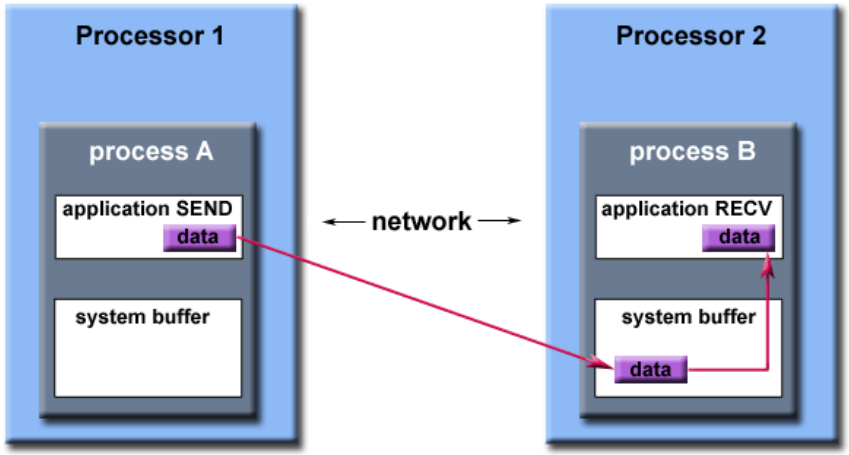

Path of a message buffered at the receiving process

Τύποι επικοινωνίας:

- Μια-προς-μια επικοινωνία (**Point-to-Point Communication**).
- Συλλογική επικοινωνία (**Collective Communication**).

Μια-προς-μια Επικοινωνία
Point-to-Point Communication

- Η αποστολή / λήψη μηνυμάτων γίνεται ανάμεσα από μόνο δύο διεργασίες. Μια διεργασία εκτελεί την αποστολή και μια την λήψη.

- Διάφοροι τύποι συναρτήσεων αποστολής/λήψης μηνυμάτων:

  - Συγχρονισμένη αποστολή (Synchronous send).
  - Περιορισμένη αποστολή / περιορισμένη λήψη (Blocking send / Blocking receive).
  - Μη-περιορισμένη αποστολή / Μη-περιορισμένη λήψη (Non-blocking send / Non-blocking receive).
  - Συνδυασμένη αποστολή/λήψη (Combined send/receive).

- Κάθε τύπος συνάρτησης αποστολής μπορεί να συνδυαστεί με οποιοδήποτε τύπο συνάρτησης λήψης.

- Υπάρχουν επίσης αρκετές συναρτήσεις-υποπρογράμματα παρακολούθησης και ελέγχου αποστολής/λήψης μηνυμάτων.

Point-to-Point Communication / Buffering

- Θεωρητικά κάθε εντολή αποστολής μπορεί να είναι συγχρονισμένη με την εντολή λήψης. Όμως αυτό είναι πολύ σπάνιο.

- Παράδειγμα:
  - Μια εντολή αποστολής εκτελείται 5 δευτερόλεπτα πριν την αντίστοιχη εντολή λήψης. Που βρίσκονται τα δεδομένα κατά τη διάρκεια της αναμονής;
  - Πολλαπλά μηνύματα φτάνουν στη ίδια διεργασία. Τι γίνεται με τα δεδομένα που βρίσκονται σε αναμονή;

- Η υλοποίηση του MPI αποφασίζει τι συμβαίνει. Συνήθως δεσμεύεται ένας Προσωρινός Χώρος Μνήμης Συστήματος (ΠΧΜΣ) (**System Buffer**).

- Προσωρινός Χώρος Μνήμης Συστήματος:
  - Διαχειρίζεται από το MPI, ο χρήστης δεν έχει πρόσβαση σε αυτόν.
  - Έχει μικρή χωρητικότητα.
  - Χρησιμοποιείται από εντολές αποστολής και λήψης.
  - Βελτιώνει την απόδοση του προγράμματος.

- Ο χώρος μνήμης που δεσμεύουν οι μεταβλητές του κώδικα ονομάζεται Προσωρινός Χώρος Μνήμης Εφαρμογής (ΠΧΜΕ) (**Application Buffer**).

Περιορισμένη/Μη-περιορισμένη Αποστολή/Λήψη

Περιορισμένη αποστολή/λήψη μηνυμάτων:

- Μια συνάρτηση περιορισμένης αποστολής θα «τερματίσει» (return) μόνο όταν ο ΠΧΜΕ μπορεί να επαναχρησιμοποιηθεί.
- Μπορεί να είναι συγχρονισμένη: υπάρχει επικοινωνία με την διεργασία που λαμβάνει για ασφαλή παραλαβή των δεδομένων.
- Μπορεί να είναι ασύγχρονη: αν ο ΠΧΜΣ «κρατάει» τα δεδομένα μέχρι αυτά να παραδοθούν.
- Μια συνάρτηση περιορισμένης λήψης θα «τερματίσει» μόνο όταν τα δεδομένα ληφθούν και μπορούν να χρησιμοποιηθούν.

Περιορισμένη/Μη-περιορισμένη Αποστολή/Λήψη

Μη-περιορισμένη (Ελεύθερη) αποστολή/λήψη μηνυμάτων:

- Οι συναρτήσεις ελεύθερης αποστολής/λήψης «τερματίζουν» αμέσως χωρίς να περιμένουν καμία επικοινωνία επιβεβαίωσης.

- Οι συναρτήσεις ελεύθερης αποστολής/λήψης απλά «απαιτούν» από την βιβλιοθήκη MPI την εκτέλεση της επικοινωνίας. Ο χρήστης δεν γνωρίζει πότε αυτό θα γίνει.

- Δεν είναι ασφαλές να αλλάζουμε τον ΠΧΜΕ (δηλαδή τις μεταβλητές-δεδομένα) πριν βεβαιωθούμε ότι η εντολή αποστολής/λήψης διεκπεραιώθηκε. Υπάρχουν κατάλληλες συναρτήσεις αναμονής (wait routines) που βοηθούν σε αυτό.

- Συνήθως χρησιμοποιούνται για την πιθανή βελτίωση της απόδοσης με ταυτόχρονη επικοινωνία και εκτέλεση των διεργασιών.

Συναρτήσεις Μια-προς-μια Επικοινωνίας

- Περιορισμένη Αποστολή: **MPI_Send (buffer, count, type, dest, tag, comm)**.
- Περιορισμένη Λήψη: **MPI_Recv (buffer, count, type, source, tag, comm, status)**.
- Ελεύθερη Αποστολή: **MPI_Isend (buffer, count, type, dest, tag, comm, request)**.
- Ελεύθερη Λήψη: **MPI_Irecv (buffer, count, type, source, tag, comm, request)**.

Ορίσματα:

- **buffer:** Τα δεδομένα που θα σταλούν/ληφθούν, τα ονόματα των μεταβλητών.
- **count:** Ο αριθμός των δεδομένων.
- **type:** Ο τύπος των δεδομένων.

Τύποι Ορισμάτων της Βιβλιοθήκης MPI

MPI C Data Types	
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	8 binary digits
MPI_PACKED	MPI_Pack(), MPI_Unpack()

Τύποι Ορισμάτων της Βιβλιοθήκης MPI

MPI Fortran Data Types	
MPI_CHARACTER	character
MPI_INTEGER	integer
MPI_REAL	real, single precision
MPI_DOUBLE_PRECISION	real, double precision
MPI_COMPLEX	complex
MPI_DOUBLE_COMPLEX	double complex
MPI_LOGICAL	logical
MPI_BYTE	8 binary digits
MPI_PACKED	MPI_Pack(), MPI_Unpack()

- Ο χρήστης μπορεί επίσης να φτιάξει τους δικούς του τύπους.
- Οι τύποι *MPI_BYTE*, *MPI_PACKED* δεν ανήκουν στους συνήθεις τύπους της C, Fortran.

Περιγραφή Ορισμάτων (συνέχεια)

- **dest:** Χρησιμοποιείται στις συναρτήσεις αποστολής και δηλώνει τον αριθμό της διεργασίας (επεξεργαστή) στην οποία θα σταλεί το μήνυμα.

- **source:** Χρησιμοποιείται στις συναρτήσεις λήψης και δηλώνει τον αριθμό της διεργασίας από την οποία θα ληφθεί το μήνυμα.

- **tag:** Αυθαίρετος θετικός ακέραιος (από 0-32767) τον οποίο θέτει ο χρήστης και είναι η ετικέτα του μηνύματος. Οι αντίστοιχες συναρτήσεις αποστολής και λήψης πρέπει να έχουν την ίδια ετικέτα.

- **comm:** Ο διαχειριστής επικοινωνίας. Προκαθορισμένος είναι ο MPI_COMM_WORLD.

- **status:** Για μια εντολή λήψης δηλώνει την πηγή και την ετικέτα του μηνύματος.

- **request:** Όρισμα της ελεύθερης αποστολής/λήψης. Εφόσον η ελεύθερη αποστολή/λήψη μπορεί να ολοκληρωθεί προτού δεσμευτεί ο απαιτούμενος προσωρινός χώρος μνήμης, δημιουργούμε έναν «αριθμό απαίτησης». Ο χρήστης μπορεί αργότερα να τον χρησιμοποιήσει (μέσω μιας συνάρτησης WAIT) για να ελέγξει την ολοκλήρωση της αποστολής/λήψης. Στη C το όρισμα αυτό είναι ένας δείκτης (pointer) στη δομή MPI_Request ενώ στη Fortran είναι ακέραιος.

Συναρτήσεις Περιορισμένης Αποστολής/Λήψης

- Περιορισμένη Αποστολή: **MPI_Send (buffer, count, type, dest, tag, comm)**. Πρότυπο της συνάρτησης στην C:

```
int MPI_Send(      void *          buf          /* input */,
                   int             count         /* input */,
                   MPI_Datatype    type          /* input */,
                   int             dest          /* input */,
                   int              tag          /* input */,
                   MPI_Comm        comm          /* input */,          )
```

- Περιορισμένη Λήψη: **MPI_Recv (buffer, count, type, source, tag, comm, status)**. Πρότυπο της συνάρτησης στην C:

```
int MPI_Recv(      void *          buf          /* input */,
                   int             count         /* input */,
                   MPI_Datatype    type          /* input */,
                   int             source        /* input */,
                   int              tag          /* input */,
                   MPI_Comm        comm          /* input */,
                   MPI_Status *    status        /* output */          )
```

Παράδειγμα Χρήσης Συναρτήσεων Περιορισμένης Αποστολής/Λήψης

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

int main(int argc, char** argv)
{
  int numtasks, rank, dest, source, rc, count, tag=1;
  char inmsg[5], outmsg[]=“hello”;
  MPI_Status Stat;
  MPI_Init(&argc,&argv);

  MPI_Comm_size(MPI_COMM_WORLD, &numtasks);
  MPI_Comm_rank(MPI_COMM_WORLD, &rank);

  if (rank == 0) {
    dest = 1; source = 1;
    MPI_Send(&outmsg, 5, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
    MPI_Recv(&inmsg, 5, MPI_CHAR, source, tag, MPI_COMM_WORLD, &stat);
 }
else if (rank == 1) {
    dest = 0; source = 0;
    MPI_Recv(&inmsg, 5, MPI_CHAR, source, tag, MPI_COMM_WORLD, &Stat);
     MPI_Send(&outmsg, 5, MPI_CHAR, dest, tag, MPI_COMM_WORLD);
 }
 MPI_Get_count(&Stat, MPI_CHAR, &count);
  printf("Task %d: Received %d char(s) from task %d with tag %d \n", rank, count, Stat.MPI_SOURCE,
             Stat.MPI_TAG);
 MPI_Finalize();
}
```

Συναρτήσεις Ελεύθερης Αποστολής/Λήψης

- Ελεύθερη Αποστολή: **MPI_Isend (buffer, count, type, dest, tag, comm, request)**. Πρότυπο της συνάρτησης στην C:

```
int MPI_Isend(      void *          buf         /* input */,
                    int             count        /* input */,
                    MPI_Datatype    type         /* input */,
                    int             dest         /* input */,
                    int              tag         /* input */,
                    MPI_Comm        comm         /* input */,
                    MPI_Request*    request      /* output */,          )
```

- Ελεύθερη Λήψη: **MPI_Irecv (buffer, count, type, source, tag, comm, request)**. Πρότυπο της συνάρτησης στην C:

```
int MPI_Irecv(      void *          buf         /* input */,
                    int             count        /* input */,
                    MPI_Datatype    type         /* input */,
                    int             source       /* input */,
                    int              tag         /* input */,
                    MPI_Comm        comm         /* input */,
                    MPI_Request*    request      /* output */,          )
```

Παράδειγμα Χρήσης Συναρτήσεων Ελεύθερης Αποστολής/Λήψης

```
program ringtopo

include 'mpif.h'
integer numtasks, rank, next, prev, buf(2), tag1, tag2, ierr

integer stats(MPI_STATUS_SIZE,4), reqs(4)
tag1 = 1; tag2 = 2

call MPI_INIT(ierr)
call MPI_COMM_RANK(MPI_COMM_WORLD, rank, ierr)
call MPI_COMM_SIZE(MPI_COMM_WORLD, numtasks, ierr)

prev = rank – 1; next = rank + 1
if (rank == 0) prev = numtasks – 1
if (rank == numtasks - 1)  next = 0

call MPI_IRECV(buf(1), 1, MPI_INTEGER, prev, tag1, MPI_COMM_WORLD, reqs(1), ierr)
call MPI_IRECV(buf(2), 1, MPI_INTEGER, next, tag2,  MPI_COMM_WORLD, reqs(2), ierr)
call MPI_ISEND(rank, 1, MPI_INTEGER, prev, tag2,  MPI_COMM_WORLD, reqs(3), ierr)
call MPI_ISEND(rank, 1, MPI_INTEGER, next, tag1,  MPI_COMM_WORLD, reqs(4), ierr)

call MPI_WAITALL(4, reqs, stats, ierr)
call MPI_FINALIZE(ierr)

stop
end
```

Συλλογική Επικοινωνία
Collective Communication

- Η συλλογική επικοινωνία περιλαμβάνει αποστολή / λήψη μηνυμάτων μεταξύ **όλων** των διεργασιών σε ένα διαχειριστή επικοινωνίας.

- Διάφοροι τύποι συναρτήσεων-υποπρογραμμάτων συλλογικής επικοινωνίας:

  - Συγχρονισμένη επικοινωνία (**Synchronization**): οι διεργασίες περιμένουν έως όλη η επικοινωνία βρεθεί στο σημείο συγχρονισμού.

  - Μεταφορά Δεδομένων (**Data Movement**): εκπομπή (broadcast), διασπορά/συγκέντρωση (scatter/gather), όλοι σε όλους (all to all).

  - Συλλογική υπολογισμοί – περιστολή (**reduction)**: μια διεργασία συλλέγει δεδομένα από όλες τις άλλες και εκτελέι μια πράξη (π.χ. πρόσθεση, πολλαπλασιασμός, κλπ.) σε αυτά τα δεδομένα.

- Οι συλλογική επικοινωνία είναι περιορισμένου (blocking) τύπου.

- Υπάρχουν επίσης συναρτήσεις παρακολούθησης και ελέγχου αποστολής/λήψης μηνυμάτων.

Υποπρογράμματα Συλλογικής Επικοινωνίας MPI

- **MPI_Barrier:** Δημιουργεί ένα σημείο συγχρονισμού. Κάθε διεργασία που φτάνει στο σημείο που το MPI_Barrier καλείται, περιμένει ως ότου όλες οι διεργασιές φτάσουν σε αυτό το σημείο

  C: *MPI_Barrier (comm);*

  Fortran: *MPI_BARRIER(comm, ierr)*

- **MPI_Bcast:** Εκπέμπει ένα μήνυμα από την διεργασία με αριθμό "root" σε όλες τις άλλες διεργασίες μέσα στον Δ.Ε.

  C: *MPI_Bcast (&buffer, count, type, root, comm);*

  Fortran: *MPI_BCAST(buffer, count, type, root, comm, ierr)*

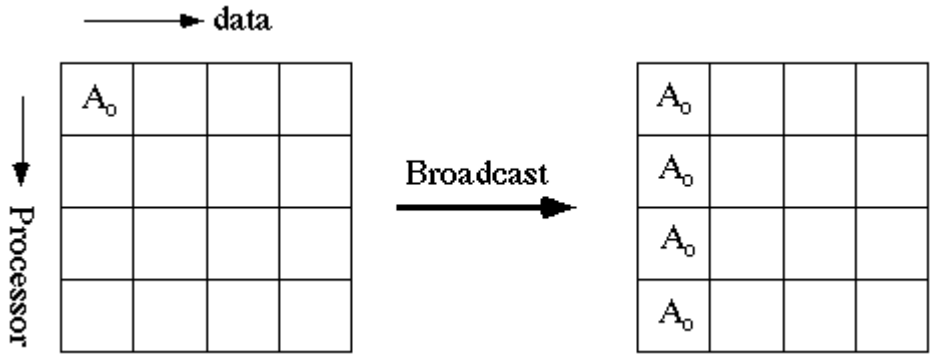

Υποπρογράμματα Συλλογικής Επικοινωνίας MPI

- **MPI_Scatter:** Διασκορπίζει ένα μήνυμα από την διεργασία με αριθμό "root" σε όλες τις άλλες διεργασίες μέσα στον Δ.Ε.
  C: *MPI_Scatter (&sendbuf, sendcnt, sendtype, &recvbuf, recv, recvtype, root, comm);*
  Fortran: *MPI_SCATTER(sendbuf, sendcnt, sendtype, recvbuf, recv, recvtype, root, comm, ierr)*

- **MPI_Gather:** Μαζεύει ένα μήνυμα από κάθε διεργασία στη διεργασια "root".
  C: *MPI_Gather (&sendbuf, sendcnt, sendtype, &recvbuf, recv, recvtype, root, comm);*
  Fortran: *MPI_SCATTER(sendbuf, sendcnt, sendtype, recvbuf, recv, recvtype, root, comm, ierr)*

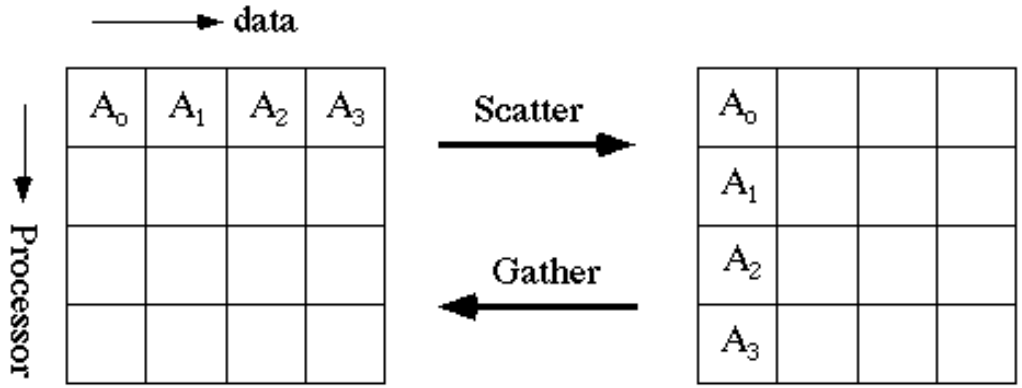

Υποπρογράμματα Συλλογικής Επικοινωνίας MPI

- **MPI_Reduce:** Εφαρμόζει μια πράξη περιστολής σε όλα τα μέλη του Δ.Ε. και στέλνει το αποτέλεσμα στη διεργασία με αριθμό "root".
  C: *MPI_Reduce (&buffer, count, type, op, root, comm);*
  Fortran: *call MPI_REDUCE(buffer, count, type, op, root, comm, ierr)*

Οι σημαντικότερες προκαθορισμένες πράξεις τύπου MPI_Reduce είναι:

MPI Reduction Operation		C Data Types	Fortran Data Types
MPI_MAX	maximum	integer, float	integer, real, complex
MPI_MIN	minimum	integer, float	integer, real, complex
MPI_SUM	sum	integer, float	integer, real, complex
MPI_PROD	product	integer, float	integer, real, complex
MPI_LAND	logical AND	integer	logical
MPI_MAXLOC	max value and location	float, double, long double	real, complex, double precision
MPI_MINLOC	min value and location	float, double, long double	real, complex, double precision

Παράδειγμα Χρήσης Υποπρογραμμάτων Συλλογικής Επικοινωνίας

```
#include "mpi.h"
#include <stdio.h>
#define SIZE 4

int main(int argc, char** argv)
{
  int numtasks, rank, sendcount, recvcount, source;
  float sendbuf[SIZE][SIZE] = { {1.0, 2.0, 3.0, 4.0}, {5.0, 6.0, 7.0, 8.0}, {9.0, 10.0, 11.0, 12.0}, {13.0, 14.0, 15.0, 16.0} };
  float recvbuf[SIZE];

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

  if (numtasks == SIZE) {
    source = 1;
    sendcount = SIZE;
    recvcount = SIZE;
    MPI_Scatter(sendbuf,sendcount,MPI_FLOAT,recvbuf,recvcount,MPI_FLOAT,source,MPI_COMM_WORLD);
    printf("rank= %d Results: %f %f %f %f\n",rank,recvbuf[0],recvbuf[1],recvbuf[2],recvbuf[3]);
  }
 else
 printf("Must  specify %d processors. Terminating.\n",SIZE);

MPI_Finalize();
}
```

Derived Datatypes

- Τα βασικά ορίσματα της βιβλιοθήκης MPI που είδαμε παραπάνω (primitive MPI Datatypes) επιτρέπουν μεταφορά απλών δεδομένων ή σύνολο μεταβλητών του ίδιου τύπου οι οποίες είναι συνεχείς (contiguous) στη μνήμη.

- **Derived Datatypes** είναι πιο πολύπλοκα ορίσματα που μπορούν να εμπεριέχουν μεταβλητές διαφορετικού είδους ή μεταβλητές που δεν είναι συνεχείς στη μνήμη.

- Τα ορίσματα MPI Derived Datatypes είναι ένα σύνολο μεταβλητών η καθεμία από τις οποίες έχει ως τύπο ένα οποιοδήποτε primitive MPI Datatype.

- **Λόγοι χρήσης:** Είναι ο μόνος τρόπος να στείλουμε με μια πράξη επικοινωνίας (μια αποστολή/λήψη) μια δομή (structure), μέρος ενός πίνακα (π.χ. Sub-block of a matrix), ή ένα σύνολο δεδομένων διαφορετικού τύπου (π.χ. int. and float numbers).

- Υπάρχουν διαφορετικοί τρόποι ορισμού ενός MPI derived datatype:
  - -- Contiguous
  - -- Vector
  - -- Indexed
  - -- Struct

Υποπρογράμματα-Συναρτήσεις MPI Derived Datatypes

-- Βασικά υποπρογράμματα δημιουργίας ορισμάτων MPI derived datatype:

- **MPI_Type_contiguous:** ο απλούστερος τρόπος. Δημιουργεί ένα καινούριο όρισμα αντιγράφοντας τα ήδη υπάρχοντα ορίσματα.
  C: *MPI_Type_contiguous (count, oldtype, &newtype)*
  Fortran: *call MPI_TYPE_CONTIGUOUS (count, oldtype, newtype, ierr)*

- **MPI_Type_vector:** παρόμοιο με το contiguous αλλά επιτρέπει κενά (stride) στις μετακινήσεις (displacements) των ορισμάτων.
  C: *MPI_Type_vector (count, blocklength, stride, oldtype, &newtype)*
  Fortran: *call MPI_TYPE_VECTOR (count, blocklength, stride, oldtype, newtype, ierr)*

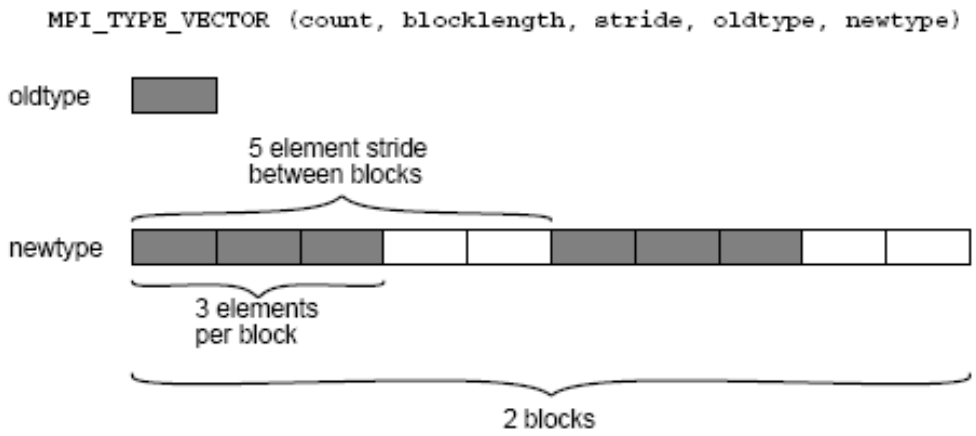

Υποπρογράμματα-Συναρτήσεις MPI Derived Datatypes

- **MPI_Type_struct:** ο πιο ευέλικτος τρόπος. Ο χρήστης ελέγχει πλήωσ τη δομή του νέου ορίσματος..
  C: *MPI_Type_struct (count, blocklens[], offsets[], old_types, &newtype)*
  Fortran: *call MPI_TYPE_STRUCT (count,blocklens[],offsets[],old_types, newtype, ierr)*

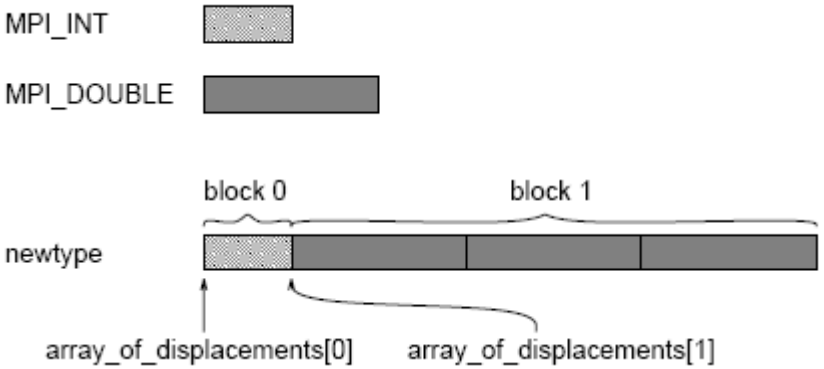

- **MPI_Type_Extend:** Επιστρέφει τον μέγεθος (σε bytes) του derived datatype ορίσματος.
  C: *MPI_Comm_rank (datatype, &extent);*
  Fortran: *call MPI_COMM_RANK(datatype, extent, ierr)*

Derived Datatypes

- **Κατασκευή ενός ορίσματος derived datatype:**

  Α) Ορισμός του ορίσματος χρησιμοποιώντας μια από τις παραπάνω υπορουτίνες (MPI_Type_contiguous, MPI_Type_vector, MPI_Type_struct, …).

  Β) Παράδοση του νέου ορίσματος. Το καινούριο όρισμα «παραδίδεται» καλώντας την:
  MPI_Type_commit(&newtype)

- **Επίσης πολύ συχνά είναι χρήσιμο να ελευθερώνετε η μνήμη από τα καινούρια ορίσματα όταν αυτά δεν χρειάζονται. Αυτό γίνεται καλώντας την ρουτίνα:**
  MPI_Type_free(&newtype)

Τοπολογία Διεργασιών Τύπου MPI

- Ο παράλληλος προγραμματισμός τύπου MPI επιτρέπει την αποτύπωση/διευθέτηση (**mapping/ordering**) των διεργασιών σε ένα γεωμετρικό σχήμα.

- Οι δύο κυριότερες τοπολογίες είναι: Η Καρτεσιανή (Grid) και η Γραφική (Graph).

- Οι τοπολογίες διεργασιών MPI είναι εικονικές: δεν υπάρχει σχέση με την τοπολογία των επεξεργαστών.

- Λόγοι χρήσης:
  - Ευκολία: Μπορεί να είναι χρήσιμες για προβλήματα με συγκεκριμένα προφίλ επικοινωνίας, π.χ. η Καρτεσιανή τοπολογία είναι κατάλληλη για προβλήματα όπου απαιτείται επικοινωνία μιας διεργασίας με της 4 γειτονικές της σε μορφή grid
  - Αποδοτικότητα: μια συγκεκριμένη τοπολογία μπορεί να βελτιστοποιήσει τις διεργασίες με βάση την αρχιτεκτονική του παράλληλου συστήματος.

- Παράδειγμα (4x4 Καρτεσιανή τοπολογία):

0 (0,0)	1 (0,1)	2 (0,2)	3 (0,3)
4 (1,0)	5 (1,1)	6 (1,2)	7 (1,3)
8 (2,0)	9 (2,1)	10 (2,2)	11 (2,3)
12 (3,0)	13 (3,1)	14 (3,2)	15 (3,3)

Παράδειγμα Δημιουργίας Καρτεσιανής Τοπολογίας

```
program cartesian
include 'mpif.h'

integer SIZE, UP, DOWN, LEFT, RIGHT
parameter(SIZE=16, UP=1, DOWN=2,  LEFT=3,  RIGHT=4)
integer numtasks, rank, source, dest, outbuf, i, tag, ierr,  inbuf(4), nbrs(4), dims(2), coords(2),
integer stats(MPI_STATUS_SIZE, 8), reqs(8), cartcomm, periods(2), reorder
data inbuf /MPI_PROC_NULL,MPI_PROC_NULL,MPI_PROC_NULL, MPI_PROC_NULL/
data dims /4,4/, tag /1/, periods /0,0/, reorder /0/

call MPI_INIT(ierr)
call MPI_COMM_SIZE(MPI_COMM_WORLD, numtasks, ierr)

 if (numtasks== SIZE) then
  call MPI_CART_CREATE(MPI_COMM_WORLD, 2, dims, periods, reorder, cartcomm, ierr)
  call MPI_COMM_RANK(cartcomm, rank, ierr)
  call MPI_CART_COORDS(cartcomm, rank, 2, coords, ierr)
  print *,'rank= ',rank,'coords= ',coords
  call MPI_CART_SHIFT(cartcomm, 0, 1, nbrs(UP), nbrs(DOWN), ierr)
  call MPI_CART_SHIFT(cartcomm, 1, 1, nbrs(LEFT), nbrs(RIGHT),  ierr)
  outbuf = rank
  do i=1,4
    dest = nbrs(i)
    source = nbrs(i)
    call MPI_ISEND(outbuf, 1, MPI_INTEGER, dest, tag,  MPI_COMM_WORLD, reqs(i), ierr)
    call MPI_IRECV(inbuf(i), 1, MPI_INTEGER, source, tag,  MPI_COMM_WORLD, reqs(i+4), ierr)
 end do
 call MPI_WAITALL(8, reqs, stats, ierr)
  print *,'rank= ',rank,' coords= ',coords,  ' neighbors(u,d,l,r)= ',nbrs print *,'rank= ',rank,' ',  ' inbuf(u,d,l,r)= ',inbuf
else
  print *, 'Must specify',SIZE,' processors. Terminating.'
end if
call MPI_FINALIZE(ierr)

end
```

Βιβλιογραφία

- *Parallel Programming*, B. Wilkinson, M. Allen, Prentice Hall, 2nd Ed. 2005.
- *Introduction to Parallel Computing*, A. Grama, G. Karypis, V. Kumar, A. Gupta, Addison-Wesley, 2003.
- *Designing and Building Parallel Programs*, Ian Foster, Addison-Wesley 1994.
- *Parallel Computing: Theory and Practice*, M. J. Quinn, McGraw-Hill, 1994.
- MPI: http://www.mpi-forum.org/
- http://www.epcc.ed.ac.uk/library/documentation/training/: On-line courses include MPI, HPF, Mesh Generation, Introduction to Computational Science, HPC in Business.

Τέλος Ενότητας