# Συστήματα Παράλληλης & Κατανεμημένης Επεξεργασίας

**Ενότητα 4:** MPI_ANY_TAG,MPI_ANY_SOURCE,MPI_Bcast, MPI_Wtime, MPI_Wait, MPI_Test, MPI_Scatter

Δρ. Μηνάς Δασυγένης

*mdasyg@ieee.org*

Εργαστήριο Ψηφιακών Συστημάτων και Αρχιτεκτονικής Υπολογιστών

*http://arch.icte.uowm.gr/mdasyg*

**Τμήμα Μηχανικών Πληροφορικής και Τηλεπικοινωνιών**

# Άδειες Χρήσης

- Το παρόν εκπαιδευτικό υλικό υπόκειται σε άδειες χρήσης Creative Commons.
- Για εκπαιδευτικό υλικό, όπως εικόνες, που υπόκειται σε άλλου τύπου άδειας χρήσης, η άδεια χρήσης αναφέρεται ρητώς.

# Χρηματοδότηση

- Το παρόν εκπαιδευτικό υλικό έχει αναπτυχθεί στα πλαίσια του εκπαιδευτικού έργου του διδάσκοντα.
- Το έργο «**Ανοικτά Ψηφιακά Μαθήματα στο Πανεπιστήμιο Δυτικής Μακεδονίας**» 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.

# Σκοπός της Ενότητας

- Η παρουσίαση βασικών δομών επικοινωνίας με το MPI.

# Το tag στις συναρτήσεις send, recv

- Σε αυτές τις συναρτήσεις η πέμπτη παράμετρος είναι το tag της επικοινωνίας.
- Το TAG είναι ένας αριθμός (π.χ. το 0).
- Γενικά το tag στην αποστολή και στη λήψη θα πρέπει να είναι το ίδιο.
- Μπορούμε όμως αντί για να δώσουμε έναν αριθμό να χρησιμοποιούμε την παράμετρο (**μόνο recv**) **MPI_ANY_TAG** η οποία δεν ορίζει κάποιο συγκεκριμένο tag.
- Μπορεί να χρησιμοποιηθεί στην λήψη (σε κάποιες υλοποιήσεις openMPI χρησιμοποιείται και στο send).

# Λήψη μηνυμάτων από οποιαδήποτε διεργασία

- Το τέταρτο όρισμα της recv (λήψης μηνυμάτων) ορίζει από ποια διεργασία περιμένει να λάβει μήνυμα.
- Είναι ένας αριθμός που υποδηλώνει το rank (π.χ. 5).
- Αν δε μας ενδιαφέρει να ορίσουμε ακριβώς τη διεργασία που θα στείλει το μήνυμα, μπορούμε αντί για τον αριθμό να χρησιμοποιήσουμε τη μεταβλητή: **MPI_ANY_SOURCE**
- Χρησιμοποιείται μόνο στη recv.

# Το όρισμα count

- Είναι η 2η παράμετρος της recv.
- Δεν αναφέρεται στο ακριβές πλήθος των στοιχείων, αλλά στο μέγιστο πλήθος των στοιχείων που αναμένουμε.
- Είναι δυνατό να είναι 0:
  - Ο αποστολέας στέλνει μόνο μια επικεφαλίδα χωρίς δεδομένα.

# Η συνάρτηση MPI_Bcast (1/3)

- Αποστολή μηνύματος σε όλες τις διεργασίες (και στον εαυτό της):
  - **MPI_Bcast (void * buffer, int count, MPI_Datatype dataType, int srcRank,**

    **MPI_Comm comm)**
    - void * buffer, pointer στο μήνυμα που θα σταλεί.
    - int count, πλήθος στοιχείων που θα σταλούν.
    - MPI_Datatype dataType, τύπος στοιχείων.
    - int srcRank, ποια διεργασία είναι αυτή που το στέλνει.
    - MPI_Comm comm σε ποιο COMMUNICATOR θα σταλεί.

# Η συνάρτηση MPI_Bcast (2/3)

- **ΠΡΟΣΟΧΗ (1)**: Δεν απαιτείται η χρήση της recv για λήψη του μηνύματος.
- **ΠΡΟΣΟΧΗ (2)**: Για να λάβει σωστά το μήνυμα μια άλλη διεργασία θα πρέπει να χρησιμοποιήσει τη συνάρτηση **MPI_Bcast** με τα ίδια ακριβώς ορίσματα που έχει χρησιμοποιήσει η αρχική συνάρτηση.
- Μετά τον τερματισμό της συνάρτησης όλες οι ενδιάμεσες μνήμες των διεργασιών του COMMUNICATOR έχουν τα ίδια περιεχόμενα.
- Αυτό γίνεται άμεσα και δε χρειάζεται παρεμβολή από τον χρήστη.

# Η συνάρτηση MPI_Bcast (3/3)

- Η MPI_Bcast μπορεί να αντικατασταθεί με ένα βρόχο για όλα τα rank ως εξής:

```
for counter=0;counter<size;counter++)
MPI_Send(&a,1,MPI_DOUBLE,counter,0,
MPI_COMM_WORLD);(προσοχή next slide)
```

- Κάθε rank θα έπρεπε να χρησιμοποιήσει την recv για να λάβει το μήνυμα.

```
MPI_Recv(&a,1,MPI_DOUBLE,0,MPI_ANY_TA
G, MPI_COMM_WORLD);
```

- Η MPI_Bcast είναι πιο γρήγορη και καλύτερη.

# Αποστολή μηνύματος στον εαυτό (send-to-itself)

- Στην προηγούμενη διαφάνεια η MPI_Send επειδή εκτελούνται για όλο το communicator size έστελνε ΚΑΙ στον εαυτό της.
- Αν και τις περισσότερες φορές θα λειτουργήσει χωρίς να κάνει block, θα πρέπει να αποφεύγεται:

"**Therefore, it is unsafe and non-portable to send self-messages with the standard mode, blocking send and receive operations described so far, since this may lead to deadlock**.«

- The book "MPI: The complete reference, Vol. 1, 2nd Ed.", by Snir et al., page 42, section 2.9.9.

# Η συνάρτηση MPI_Wtime()

- Χρησιμοποιείται για να μετρήσει το χρόνο εκτέλεσης ενός τμήματος κώδικα.
- Πρότυπο:

  **double MPI_Wtime(void)**
- Μπορεί να χρησιμοποιηθεί ώστε να μας δώσει πληροφορίες για την χρονική στιγμή έναρξης ή λήξης ενός προγράμματος. Αν καλέσουμε τη συνάρτηση αυτή στην αρχή μιας διαδικασίας (π.χ. μετά την MPI_Comm_size) και μια στο τέλος (πριν την MPI_Finalize), τότε η διαφορά τους θα μας δώσει τον χρόνο εκτέλεσης του προγράμματος σε δευτερόλεπτα.

# Παράδειγμα MPI_Wtime()

```
double startwtime, endwtime;
startwtime = MPI_Wtime();
(.....κομμάτι κώδικα....)
endwtime = MPI_Wtime();
printf ("wall clock time = %f \n",
endwtimefstartwtime);
```

# Άλλες ενδιαφέρουσες ρουτίνες

- **MPI_Wait**(MPI_Request *req, MPI_Status *status).
  - Περιμένει εώς ότου η επικοινωνία αναφοράς req λήξει.
- **MPI_Test**(MPI_Request *req, int *flag, MPI_Status *status).
  - Επιστρέφει flag=TRUE εφόσον η επικοινωνία αναφοράς  req έχει λήξει επιτυχώς και flag=FALSE σε άλλη περίπτωση.

# Συλλογικές κλήσεις

- Κάθε διεργασία εκτελεί τις ίδιες ρουτίνες επικοινωνίας με τις υπόλοιπες.
- Δεν χρησιμοποιούνται tags αλλά communicators.
- Δεν υπάρχουν non-blocking συλλογικές κλήσεις.
- Τρεις τύποι:
  - Συγχρονισμός.
  - Μετακίνηση δεδομένων.
  - Συλλογικοί υπολογισμοί.

# Παραδείγματα συλλογικών κλήσεων

- **MPI_Barrier**(MPI_Comm communicator).
  - παγώνει όλες τις διεργασίες έως ότου αυτές φτάσουν στο συγκεκριμένο σημείο ελέγχου. Όταν όλες οι διεργασίες εκτελέσουν τη MPI_Barrier τότε συνεχίζεται η εκτέλεση όλων κανονικά.
- **MPI_Bcast**(void *buf, int count, MPI_Datatype data_type, int root, MPI_Comm comm).
  - Σήμα one-to-all (αναπτύχθηκε σε προηγούμενη παρουσίαση).

# Η συνάρτηση MPI_Scatter() (1/5)

- Συνάρτηση διαμοιρασμού δεδομένων σε όλες τις διεργασίες της ομάδας.
- Η συνάρτηση MPI_Scatter ανήκει στην κατηγορία των συναρτήσεων που πραγματοποιούν συλλογικές επικοινωνίες (collective communications). Το βασικό χαρακτηριστικό των συναρτήσεων συλλογικής επικοινωνίας είναι ότι κάποια διεργασία ανταλλάσσει δεδομένα προς όλες τις υπόλοιπες διεργασίες.

**Int MPI_Scatter (void * sendBuf, int sendCount, MPI_Datatype sendType,void * recvBuf, int recvCount, MPI_Datatype recvType, int root,MPI_Comm comm);**

# Η συνάρτηση MPI_Scatter() (2/5)

- **sendBuf:** Περιοχή μνήμης που είναι τα δεδομένα προς διασπορά.
- **sendCount:** Πλήθος δεδομένων προς διασπορά **ανά διεργασία.**
- **sendType:** Τύπος δεδομένων προς διασπορά.
- **recvBuf:** Περιοχή μνήμης που θα αποθηκευθούν τα δεδομένα από την διεργασία παραλήπτη.
- **recvCount:** Πλήθος δεδομένων που παραλαμβάνονται ανά διεργασία.
- **recvType:** Τύπος δεδομένων που παραλαμβάνονται.
- **root:** Η διεργασία ρίζα που πρόκειται να διασπείρει τα δεδομένα.
- **comm:** Ο χειριστής στον οποίο ανήκουν οι διεργασίες αποστολής (MPI_COMM_WORLD).

# Η συνάρτηση MPI_Scatter() (3/5)

- Συγκεκριμένα, η MPI_Scatter κάνει διασπορά δεδομένων (Scattering), όπου τα δεδομένα μίας διεργασίας μοιράζονται με κατάλληλο τρόπο σε όλες τις υπόλοιπες καθώς και στον εαυτό της. Δεν απαιτείται να ξεκινήσει η κάθε διεργασία-παραλήπτης μια συνάρτηση MPI_Recv για την παραλαβή των δεδομένων.
- Παράδειγμα: Έστω ένας πίνακας: Α με 300 ακεραίους και 3 διεργασίες, η κλήση της συνάρτησης:

  **MPI_Scatter (&A, 100, MPI_INT, &B, 100, MPI_INT, 0, MPI_COMM_WORLD);**

- Θα έχει σαν αποτέλεσμα η διεργασία 0 να διασπείρει τα δεδομένα του πίνακα Α, οι 3 διεργασίες θα παραλάβουν στον πίνακα Β: τα 100 πρώτα στοιχεία η διεργασία 0, τα 100 επόμενα η διεργασία 1 και τα 100 τελευταία η διεργασία 2.

# Η συνάρτηση MPI_Scatter() (4/5)

- Η συνάρτηση διαμοιράζει τα δεδομένα σε όλες τις διεργασίες της ομάδας.

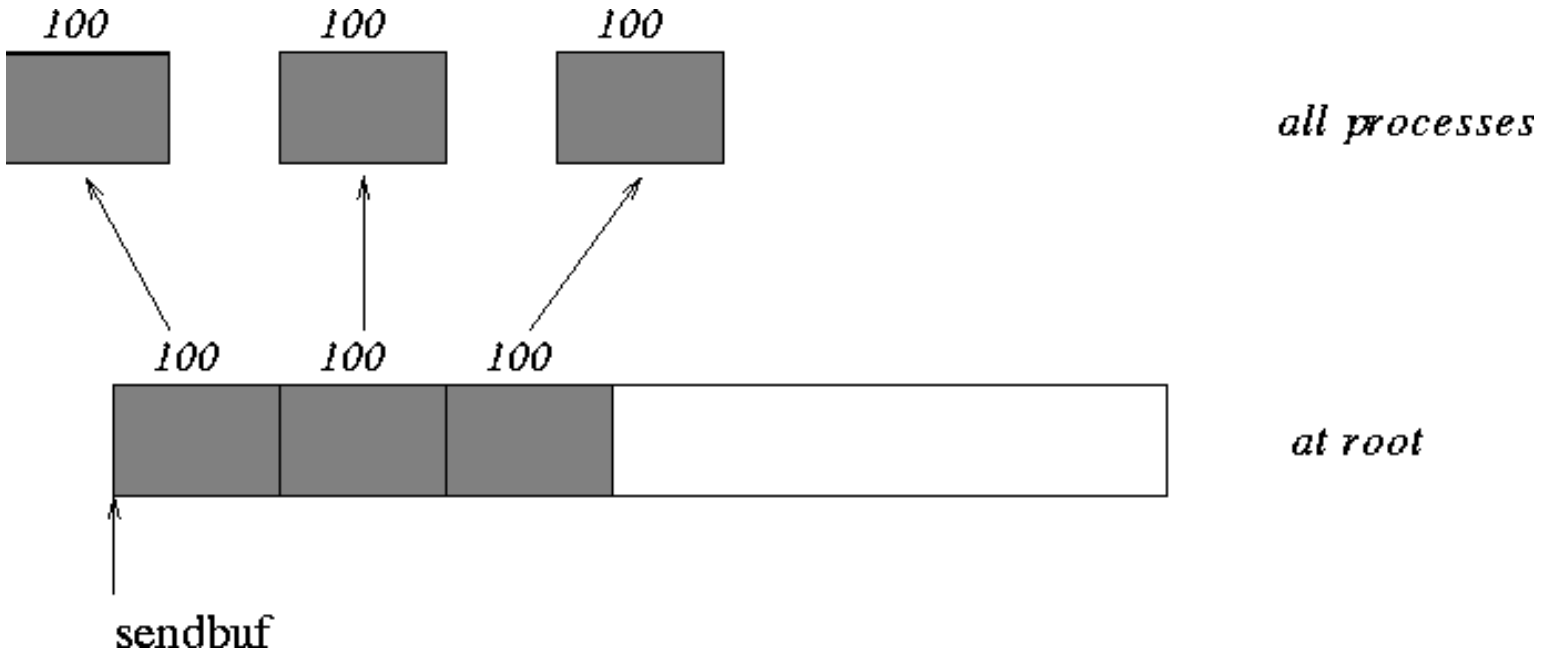

# Η συνάρτηση MPI_Scatter() (5/5)

- Προσοχή:
  - Μπορούν να διαμοιραστούν ΜΟΝΟ ομάδες με διακριτά στοιχεία Για παράδειγμα δε μπορούμε να πούμε να διαμοιράσουμε τους πραγματικούς αριθμούς από 0 έως 1 σε Ν διεργασίες.
  - Αν όμως είχαμε έναν πίνακα με πραγματικούς αριθμούς θα μπορούσε να διαμοιραστεί.

# Τέλος Ενότητας