

Προηγμένες αρχιτεκτονικές υπολογιστών και προγραμματισμός παραλλήλων συστημάτων


LAB-10. MPI (Μέρος F) –
Τοπολογίες διεργασιών,
Communicators

Τοπολογίες διεργασιών

- Ως τοπολογία διεργασιών ορίζεται η οργάνωση των διεργασιών MPI σύμφωνα με κάποιο κριτήριο.
- Δοθείσας μιας διεργασίας, καθίσταται εύκολος ο προσδιορισμός των γειτονικών διεργασιών.
- Χρήσιμο για επίλυση συγκεκριμένων αλγορίθμων (π.χ. επεξεργασία εικόνας ή σήματος).
- Παραδείγματα τοπολογιών:
 - 2-Δ Πλέγμα: Καρτεσιανή τοπολογία
 - 1-Δ: Δακτύλιος

Πλέγμα δύο διαστάσεων

- Παράδειγμα πλέγματος διεργασιών 4 x 5.



MPI_Cart_create


- Η συνάρτηση `MPI_Cart_create` κάνει n-διάστατη καρτεσιανή τακτοποίηση των διεργασιών.
- Δημιουργεί ένα νέο communicator στον οποίο έχει προστεθεί πληροφορία καρτεσιανής τοπολογίας.
- **`int MPI_Cart_create(MPI_Comm comm_old, int ndims, const int dims[], const int pers[], int reorder, MPI_Comm * comm_cart)`**
 - `comm_old`: Communicator εισόδου (ο δημιουργός).
 - `ndims`: Το πλήθος των διαστάσεων (π.χ. `ndims = 2` για το 2D πλέγμα του προηγούμενου παραδείγματος).

MPI_Cart_create

- **int MPI_Cart_create(MPI_Comm comm_old, int ndims, const int dims[], const int pers[], int reorder, MPI_Comm * comm_cart)**
 - **dims[]**: πίνακας ακεραίων μεγέθους **ndims**. Δηλώνει τον αριθμό διεργασιών ανά διάσταση πλέγματος.
 - **pers[]**: λογικός πίνακας μεγέθους **ndims**. Δηλώνει αν το πλέγμα είναι περιοδικό (**true**) σε κάθε διάσταση.
 - **reorder**: Λογική μεταβλητή. Δηλώνει αν τα **ranks** των διεργασιών μπορούν να αναδιαταχθούν.
 - **comm_cart**: Ο νέος **communicator** με καρτεσιανή τοπολογία.


Περιοδικά/Μη-περιοδικά πλέγματα

- Ποιος είναι ο δεξιός γείτονας της διεργασίας $(1,4)$;



Το όρισμα `periods` (1)


- Λογικός πίνακας μεγέθους `ndims`. Δηλώνει αν το πλέγμα είναι περιοδικό (`true`) σε κάθε διάσταση.



- Εδώ: `periods[0] = true`;
- Ομοίως για τις άλλες διαστάσεις (π.χ. `periods[1]`).

Το όρισμα `periods` (2)

- Εδώ: `periods[0] = false;`



- Ομοίως για τις άλλες διαστάσεις (π.χ. `periods[1]`).

Rank και συντεταγμένες διεργασίας

- Το rank μιας διεργασίας στον νέο communicator επιστρέφεται κατά τα γνωστά με την `MPI_Comm_rank`.
- Οι συντεταγμένες μιας διεργασίας πάνω στο καρτεσιανό πλέγμα επιστρέφονται με χρήση της `MPI_Cart_coords`.
- Περνιέται ως όρισμα ο νέος communicator και το rank της διεργασίας στον νέο communicator.

MPI_Cart_coords

- Επιστρέφονται οι συντεταγμένες μιας διεργασίας μέσα σε μία καρτεσιανή τοπολογία.
- **int MPI_Cart_coords(MPI_Comm comm, int rank, int maxdims, int coords[])**
 - **comm**: ο communicator με καρτεσιανή τοπολογία.
 - **rank**: η τάξη τα διεργασίας **μέσα στον comm**.
 - **maxdims**: το μέγεθος του πίνακα **coords**.
 - **coords[]**: πίνακας μεγέθους **maxdims** στον οποίο αποθηκεύονται οι συντεταγμένες της διεργασίας σε κάθε διάσταση του πλέγματος.

```
int main(int argc, char** argv) {
    int NumProcs, ProcRank, ProcCoordinates[2];

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

    int CommDims[2] = {4, 5};           /// The 2d topology: 4 rows, 5 cols.
    int CommPers[2] = {true, true};    /// Both dimensions will be periodic.
    int reorder = true;                /// Assign arbitrary ranks.

    /// Create a communicator given the specified 2D topology.
    MPI_Comm CNEW;
    MPI_Cart_create(MPI_COMM_WORLD, 2, CommDims, CommPers, reorder, &CNEW);

    /// Get the rank and the coordinates of the current process in CNEW
    MPI_Comm_rank(CNEW, &ProcRank);
    MPI_Cart_coords(CNEW, ProcRank, 2, ProcCoordinates);

    printf("[MPI process %d] I am located at (%d, %d).\n",
           ProcRank, ProcCoordinates[0], ProcCoordinates[1]);

    MPI_Finalize();
    return EXIT_SUCCESS;
}
```

Γειτονικές διεργασίες

- Η `MPI_Cart_create` δημιουργεί ένα νέο communicator με τις ίδιες διεργασίες όπως ο αρχικός communicator εισόδου, αλλά με τη συγκεκριμένη τοπολογία.
- Η εύρεση των γειτονικών διεργασιών πραγματοποιείται με την κλήση της συνάρτησης `MPI_Cart_shift`.
- Η συνάρτηση δέχεται μία μετατόπιση προς μία συγκεκριμένη κατεύθυνση και επιστρέφει τα ranks των αντίστοιχων διεργασιών πηγής και προορισμού.

MPI_Cart_shift

- Επιστρέφει τα ranks των διεργασιών πηγής και προορισμού με δεδομένη την κατεύθυνση και το βήμα της μετατόπισης.
- **int MPI_Cart_shift(MPI_Comm comm, int direction, int disp, int *src, int *dest)**
 - `comm`: communicator με καρτεσιανή τοπολογία.
 - `direction`: η διάσταση της μετατόπισης.
 - `disp`: το βήμα της μετατόπισης
 - `src`: rank της διεργασίας-πηγής.
 - `dest`: rank της διεργασίας-προορισμού.

MPI_Cart_shift

```
int NeighboursRanks[4];
char * directions[4] = {"Up", "Right", "Down", "Left" };

MPI_Cart_shift(COMM_NEW, 0, 1, &NeighboursRanks[0],
               &NeighboursRanks[2]);

MPI_Cart_shift(COMM_NEW, 1, 1, &NeighboursRanks[3],
               &NeighboursRanks[1]);

printf("\tNeighbours:\n");
for (int i = 0; i < 4; i++) {
    if (NeighboursRanks[i] == MPI_PROC_NULL) {
        printf("\t\t%s: NO NEIGHBOUR\n", directions[i]);
    } else {
        printf("\t\t%s: %d\n", directions[i], NeighboursRanks[i]);
    }
}
```

MPI_Graph_create

- Η συνάρτηση `MPI_Graph_create` επιτρέπει γενικά τη δημιουργία μιας τοπολογίας που περιγράφεται από οποιοδήποτε γράφο.
- **`int MPI_Graph_create(MPI_Comm comm_old, int nnodes, const int indx[], const int edges[], int reorder, MPI_Comm * comm_grp)`**
 - `comm_old`: Communicator εισόδου (ο δημιουργός).
 - `nnodes`: το πλήθος κόμβων στο γράφο.
 - `index`: πίνακας που περιγράφει τους βαθμούς των κόμβων.
 - `edges`: πίνακας που περιγράφει τις ακμές του γράφου.
 - `reorder`: το αγνοούμε.
 - `comm_grp`: communicator με την τοπολογία γράφου.

Χρησιμότητα τοπολογιών

- Σε πολλές παράλληλες διασυνδέσεις υπολογιστών, κάποιοι υπολογιστές είναι πιο κοντά από κάποιους άλλους. Οι συναρτήσεις αυτές προσφέρουν μια διευθέτηση των διεργασιών σε μια τοπολογία η οποία κάνει τους «λογικούς» γείτονες να είναι κοντά στους φυσικούς «γείτονες».
- Κάποια συστήματα έχουν διάφορες τοπολογίες με πολλαπλά μονοπάτια που τροποποιούν τους γείτονες σε διαφορετικούς χρόνους. Οι συναρτήσεις αυτές απαλλάσσουν τον προγραμματιστή από την επίλυση θεμάτων τοπολογίας.

Groups διεργασιών

- Το MPI δίνει τη δυνατότητα ομαδοποίησης διεργασιών.
- Σκοπός της ομαδοποίησης είναι κυρίως η μετέπειτα διαχείριση των διεργασιών από κάποιο communicator.
- Είναι όμως δυνατή και η διαχείριση μέσω συναρτήσεων ένωσης (`MPI_Group_union`) και τομής (`MPI_Group_intersection`).

MPI_Comm_group

- Λήψη του group διεργασιών που διαχειρίζεται ένας συγκεκριμένος communicator.
- **int MPI_Comm_group(MPI_Comm comm, MPI_Group * group)**
 - **comm**: ο communicator του οποίου τις διεργασίες θα λάβουμε.
 - **group**: επιστρέφεται το group των διεργασιών σε ένα αντικείμενο MPI_Group.

MPI_Group_size

- Επιστρέφει το πλήθος των διεργασιών σε ένα group.
- **int MPI_Group_size(MPI_Group group, int *size)**
 - **group**: Το group των διεργασιών.
 - **size**: επιστρέφεται το πλήθος των διεργασιών στο group.

MPI_Group_free

- Καταργεί (απελευθερώνει) μια ομαδοποίηση.
- **int MPI_Group_free(MPI_Group *group)**
 - group: Το group των διεργασιών που θα καταργηθεί.

Παράδειγμα

```
int main (int argc, char** argv) {  
    MPI_Init(&argc, &argv);  
  
    // Get the group from the default communicator  
    MPI_Group group;  
    MPI_Comm_group(MPI_COMM_WORLD, &group);  
  
    // Get the size of the group  
    int size;  
    MPI_Group_size(group, &size);  
  
    // Each process prints the number of processes in the group  
    printf("We are %d MPI processes in the group of the default  
           communicator MPI_COMM_WORLD.\n", size);  
  
    MPI_Finalize();  
  
    return EXIT_SUCCESS;  
}
```

Συναρτήσεις δημιουργίας group (1)

- Οι ακόλουθες συναρτήσεις δημιουργούν group διεργασιών από άλλα, ήδη υπάρχοντα group.
- Δημιουργία group από πίνακα με ranks διεργασιών:
 - `int MPI_Group_incl (MPI_Group group, int n, int *ranks, MPI_Group *group_out)`
 - `ranks`: ο πίνακας με τα ακέραια ranks των διεργασιών.
- Δημιουργία group από πίνακα με ranges διεργασιών:
 - `int MPI_Group_range_incl (MPI_Group group, int n, int ranges[][3], MPI_Group *newgroup)`
 - `ranges`: πίνακας τριάδων (first rank, last rank, stride).
 - `n`: πλήθος τριάδων.

Συναρτήσεις δημιουργίας group (2)

- Δημιουργία group από ένωση δύο άλλων groups:
 - `int MPI_Group_union(MPI_Group group1, MPI_Group group2, MPI_Group *group_out)`
 - `group1, group2`: τα groups που θα ενωθούν.
- Δημιουργία group από την τομή δύο άλλων groups:
 - `int MPI_Group_intersection (MPI_Group group1, MPI_Group group2, MPI_Group *group_out)`
 - `group1, group2`: τα groups των οποίων η τομή θα υπολογιστεί.

Communicators από groups διεργασιών

- Πέραν των τοπολογιών, το MPI προσφέρει τη δυνατότητα απευθείας δημιουργίας νέων communicators χρησιμοποιώντας συγκεκριμένα μέλη από έναν άλλο communicator.
- Δηλαδή communicators μπορούν να δημιουργούνται απευθείας από δοθέντα groups διεργασιών.

MPI_Comm_create

- Δημιουργία communicator από δοθέν group διεργασιών.
- **int MPI_Comm_create(MPI_Comm comm, MPI_Group group, MPI_Comm *newcomm)**
 - **comm**: communicator εισόδου (ο δημιουργός).
 - **group**: το group εισόδου των διεργασιών. Πρέπει να είναι υποσύνολο του comm.
 - **newcomm**: ο νέος communicator αποτελείται από τις διεργασίες της ομαδοποίησης group.

Παράδειγμα (1)

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

int main (int argc, char ** argv) {
    int NumProcs, ProcRank;
    MPI_Init(&argc, &argv);
    MPI_Comm_size(MPI_COMM_WORLD, &NumProcs);

    /// Get the group or processes of the default communicator
    MPI_Group world_group;
    MPI_Comm_group(MPI_COMM_WORLD, &world_group);

    /// Keep only the processes 0 and 1 in the new group.
    int ranks[2] = {0, 1};
    MPI_Group new_group;
    MPI_Group_incl(world_group, 2, ranks, &new_group);

    /// Create the new communicator from that group of processes.
    MPI_Comm new_communicator;
    MPI_Comm_create(MPI_COMM_WORLD, new_group, &new_communicator);
```

Παράδειγμα (2)

```
/// Do a broadcast between all processes
MPI_Comm_rank(MPI_COMM_WORLD, &ProcRank);
int value = 10;
MPI_Bcast(&value, 1, MPI_INT, 0, MPI_COMM_WORLD);
printf("Process %d took part to the global comm broadcast.\n", ProcRank);

/// Wait all processes before proceeding to the second phase.
MPI_Barrier(MPI_COMM_WORLD);

/// Do a broadcast only between the processes of the new communicator.
if (new_communicator == MPI_COMM_NULL) {
    printf("Process %d is OUT of the new comm broadcast.\n\n", ProcRank);
} else {
    MPI_Bcast(&value, 1, MPI_INT, 0, new_communicator);
    printf("Process %d took part in the new comm broadcast.\n\n", ProcRank);
}

MPI_Finalize();

return EXIT_SUCCESS;
}
```