MPI

1 – Vous rentrerez le programme suivant afin de tester votre cluster :

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

int main(int argc, char** argv) {
    // Initialize the MPI environment
    MPI_Init(NULL, NULL);

    // Get the number of processes
    int world_size;
    MPI_Comm_size(MPI_COMM_WORLD, &world_size);

    // Get the rank of the process
    int world_rank;
    MPI_Comm_rank(MPI_COMM_WORLD, &world_rank);

    // Get the name of the processor
    char processor_name[MPI_MAX_PROCESSOR_NAME];
    int name_len;
    MPI_Get_processor_name(processor_name, &name_len);

    // Print off a hello world message
    printf("Hello world from processor %s, rank %d out of %d processors\n",
           processor_name, world_rank, world_size);

    // Finalize the MPI environment.
    MPI_Finalize();
}
```

Vous vérifierez que la fonction `MPI_Get_processor_name` affiche bien les différents noms de votre cluster.

2 – Vous récupérerez les fichiers : Disponibles sur :

`https://github.com/wesleykendall/mpitutorial/tree/gh-pages/tutorials/mpi-send-and-receive/code`

Questions :

a. Pour le programme `send_recv`, **combien** de nœuds vont travailler ?

```
 1 // Author: Wes Kendall
 2 // MPI_Send, MPI_Recv example. Communicates the number -1 from process 0
 3 // to process 1.
 4 #include <mpi.h>
 5 #include <stdio.h>
 6 #include <stdlib.h>
 7
 8 int main(int argc, char** argv) {
 9   // Initialize the MPI environment
10   MPI_Init(NULL, NULL);
11   // Find out rank, size
12   int world_rank;
13   MPI_Comm_rank(MPI_COMM_WORLD, &world_rank);
14   int world_size;
15   MPI_Comm_size(MPI_COMM_WORLD, &world_size);
16
17   // We are assuming at least 2 processes for this task
18   if (world_size < 2) {
19     fprintf(stderr, "World size must be greater than 1 for %s\n", argv[0]);
20     MPI_Abort(MPI_COMM_WORLD, 1);
21   }
22
23   int number;
24   if (world_rank == 0) {
25     // If we are rank 0, set the number to -1 and send it to process 1
26     number = -1;
27     MPI_Send(
28       /* data         = */ &number,
```

```
29        /* count        = */ 1,
30        /* datatype     = */ MPI_INT,
31        /* destination  = */ 1,
32        /* tag          = */ 0,
33        /* communicator = */ MPI_COMM_WORLD);
34    } else if (world_rank == 1) {
35      MPI_Recv(
36        /* data         = */ &number,
37        /* count        = */ 1,
38        /* datatype     = */ MPI_INT,
39        /* source       = */ 0,
40        /* tag          = */ 0,
41        /* communicator = */ MPI_COMM_WORLD,
42        /* status       = */ MPI_STATUS_IGNORE);
43      printf("Process 1 received number %d from process 0\n", number);
44    }
45    MPI_Finalize();
46  }
```

- ◇ *Ligne 18, on vérifie qu'il y a au moins deux nœuds lancés ;*
- ◇ *Ligne 24 : on teste si on est le nœud de rang 0 et dans ce cas là on envoie la valeur* -1 *de la variable de* `number` *vers le nœud de rang* `1` *;*
- ◇ *Ligne 34 : on teste si on est le nœud de rang 1, et si c'est le cas on reçoit la valeur envoyée par le nœud de rang 0.*

$\Longrightarrow$ *seuls deux nœuds vont travailler.*

b. Dans le programme `ping_pong`, comment sont choisis les « partenaires » de ping-pong ?
Il y a seulement deux nœuds utilisés dans le cluster qui exécutent le ***même code****, il est donc nécessaire de* ***casser la symétrie*** *en utilisant le rang unique du nœud dans le cluster : chaque nœud va déterminer en ligne 27 son «* partner *» : 0* $\Longrightarrow$ *1 et 1* $\Longrightarrow$ *0.*

```
 1  // Author: Wes Kendall
 2  // Ping pong example with MPI_Send and MPI_Recv. Two processes ping pong a
 3  // number back and forth, incrementing it until it reaches a given value.
 4  //
 5  #include <mpi.h>
 6  #include <stdio.h>
 7  #include <stdlib.h>
 8
 9  int main(int argc, char** argv) {
10    const int PING_PONG_LIMIT = 10;
11
12    // Initialize the MPI environment
13    MPI_Init(NULL, NULL);
14    // Find out rank, size
15    int world_rank;
16    MPI_Comm_rank(MPI_COMM_WORLD, &world_rank);
17    int world_size;
18    MPI_Comm_size(MPI_COMM_WORLD, &world_size);
19
20    // We are assuming at least 2 processes for this task
21    if (world_size != 2) {
22      fprintf(stderr, "World size must be two for %s\n", argv[0]);
23      MPI_Abort(MPI_COMM_WORLD, 1);
24    }
25
26    int ping_pong_count = 0;
27    int partner_rank = (world_rank + 1) % 2;
28    while (ping_pong_count < PING_PONG_LIMIT) {
29      if (world_rank == ping_pong_count % 2) {
30        // Increment the ping pong count before you send it
31        ping_pong_count++;
32        MPI_Send(&ping_pong_count, 1, MPI_INT, partner_rank, 0, MPI_COMM_WORLD);
33        printf("%d sent and incremented ping_pong_count %d to %d\n",
34               world_rank, ping_pong_count, partner_rank);
35      } else {
36        MPI_Recv(&ping_pong_count, 1, MPI_INT, partner_rank, 0, MPI_COMM_WORLD,
37                 MPI_STATUS_IGNORE);
38        printf("%d received pin g_pong_count %d from %d\n",
39               world_rank, ping_pong_count, partner_rank);
40      }
41    }
42    MPI_Finalize();
43  }
```

Est-ce que le programme peut **bloquer** ?
Il y a alternance des rôles d'envoi et de réception de la valeur de la variable `ping_pong_count` *qui n'est incrémenter que par l'émetteur mais mise à jour chez le récepteur lors de la réception. Une*

borne max est définie pour cette variable qui quand elle est atteinte force la terminaison du nœud ⟹ il ne peut y avoir de blocage.

Est-il possible d'ajouter une **étiquette** différente par ping-pong ?
Oui, on peut se servir de la valeur de la variable `ping_pong_count` comme étiquette, en oubliant pas de l'incrémenter lors de la réception :

```
28 while (ping_pong_count < PING_PONG_LIMIT) {
29   if (world_rank == ping_pong_count % 2) {
30     // Increment the ping pong count before you send it
31     ping_pong_count++;
32     MPI_Send(&ping_pong_count, 1, MPI_INT, partner_rank, ping_pong_count, MPI_COMM_WORLD);
33     printf("%d sent and incremented ping_pong_count %d to %d\n",
34            world_rank, ping_pong_count, partner_rank);
35   } else {
36     ping_pong_count++;
37     MPI_Recv(&ping_pong_count, 1, MPI_INT, partner_rank, ping_pong_count,
MPI_COMM_WORLD,
38              MPI_STATUS_IGNORE);
39     printf("%d received ping_pong_count %d from %d\n",
40            world_rank, ping_pong_count, partner_rank);
41   }
42 }
```

c. Pour le programme `ring`, comment est créer « *l'anneau* » ?
L'anneau est défini par le rang du nœud dans le cluster :
- `rang-1` *désigne le nœud situé à gauche du nœud courant ;*
- `rang+1` *désigne le nœud situé à droite du nœud courant.*
- *le nœud de rang* `0` *est lié au nœud de rang* `world_size - 1` *et vice-versa grâce à l'expression* `(world_rank + 1) % world_size;`

```
 1 // Author: Wes Kendall
 2 // Example using MPI_Send and MPI_Recv to pass a message around in a ring.
 3 //
 4 #include <mpi.h>
 5 #include <stdio.h>
 6 #include <stdlib.h>
 7
 8 int main(int argc, char** argv) {
 9   // Initialize the MPI environment
10   MPI_Init(NULL, NULL);
11   // Find out rank, size
12   int world_rank;
13   MPI_Comm_rank(MPI_COMM_WORLD, &world_rank);
14   int world_size;
15   MPI_Comm_size(MPI_COMM_WORLD, &world_size);
16
17   int token;
18   // Receive from the lower process and send to the higher process. Take care
19   // of the special case when you are the first process to prevent deadlock.
20   if (world_rank != 0) {
21     MPI_Recv(&token, 1, MPI_INT, world_rank - 1, 0, MPI_COMM_WORLD,
22              MPI_STATUS_IGNORE);
23     printf("Process %d received token %d from process %d\n", world_rank, token,
24            world_rank - 1);
25   } else {
26     // Set the token's value if you are process 0
27     token = -1;
28   }
29   MPI_Send(&token, 1, MPI_INT, (world_rank + 1) % world_size, 0,
30            MPI_COMM_WORLD);
31   // Now process 0 can receive from the last process. This makes sure that at
32   // least one MPI_Send is initialized before all MPI_Recvs (again, to prevent
33   // deadlock)
34   if (world_rank == 0) {
35     MPI_Recv(&token, 1, MPI_INT, world_size - 1, 0, MPI_COMM_WORLD,
36              MPI_STATUS_IGNORE);
37     printf("Process %d received token %d from process %d\n", world_rank, token,
38            world_size - 1);
39   }
40   MPI_Finalize();
41 }
```

Pourquoi doit-on modifier le **comportement** du nœud de rang 0 ?
Car c'est le nœud de rang `0` *qui transmet initialement le token et le reçoit à la fin du nœud de rang le plus élevé.*

Pouvez vous ajouter un « *token* » qui s'incrémente à chaque envoi d'un nœud à l'autre ?

Oui, il suffit d'en incrémenter la valeur juste avant de l'émettre :

```
29 token++;
30 MPI_Send(&token, 1, MPI_INT, (world_rank + 1) % world_size, 0,
31          MPI_COMM_WORLD);
```

Est-ce que le nœud 0 peut connaitre le **nombre de nœuds** par la valeur du token qu'il reçoit au final ?
Par rapport à la modification précédente, le nœud `0` reçoit le rang de processus le plus élevém il lui suffit de l'incrémenter pour déterminer le nombre total de nœuds.

xterm

```
$ mpirun -n 4 ./ring
Process 1 received token 0 from process 0
Process 0 received token 3 from process 3
Process 2 received token 1 from process 1
Process 3 received token 2 from process 2
```

3 – Vous écrirez un programme réalisant la **somme d'entiers en utilisant une structure d'arbre** :

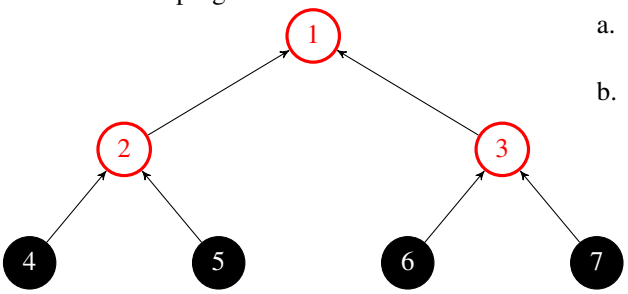

a. Comment chaque nœud va connaitre le rang de son parent ?

b. les nœuds 4,5,6 et 7 vont chacun envoyer un entier à leur parent respectif 2 et 3 qui va en faire la somme, avant de l'envoyer au nœud 1.

Écrivez un programme MPI réalisant ce travail en utilisant le rang du nœud feuille comme valeur entière à transmettre.

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

#define PARENT(n) (ceil(n/2)-1)
#define ENFANTG(n) (n*2-1)
#define ENFANTD(n) (n*2)

int main (int argc, char *argv[])
{   int rank, nprocs;
    int niveaux, numero;
    int premier = 0;
    int dernier = 0;
    long int resultat = 0;
    MPI_Status status;
    long int resultat_enfantd = 0;
    long int resultat_enfantg = 0;

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

    assert(!(nprocs+1-pow(2,log2(nprocs+1))));
    numero = rank+1;
    niveaux = log2(nprocs+1);
    premier = 1<<(niveaux-1);
    dernier = (1<<niveaux)-1;

    if (numero == 1)
    {/* Racine de l'arbre */
   printf("Niveaux : %d\n",niveaux);
   printf("Numero: %d, dernier niveau de %d a %d\n", numero, premier, dernier);
   printf("Numero: %d reception de %d\n", numero, ENFANTD(numero)+1);
   printf("Numero: %d reception de %d\n", numero, ENFANTG(numero)+1);
    MPI_Recv (&resultat_enfantd, 1, MPI_LONG_LONG, ENFANTD(numero), 1, MPI_COMM_WORLD,
&status);
    MPI_Recv (&resultat_enfantg, 1, MPI_LONG_LONG, ENFANTG(numero), 1, MPI_COMM_WORLD,
&status);
   resultat = numero + resultat_enfantg + resultat_enfantd;
   printf("La somme de l'arbre vaut %ld\n", resultat);
   MPI_Finalize();
   return 0;
    }
    if ((numero >= premier) && (numero <= dernier))
    {/* Noeud au dernier niveau */
   resultat = numero;
   printf("Numero: %d envoi de %ld\n", numero, resultat);
   MPI_Send(&resultat, 1, MPI_LONG_LONG, PARENT(numero), 1, MPI_COMM_WORLD);
   MPI_Finalize ();
   return 0;
    }
    /* Noeud de l'arbre avec des enfants */
    printf("Numero: %d reception de %d\n", numero, ENFANTD(numero)+1);
    printf("Numero: %d reception de %d\n", numero, ENFANTG(numero)+1);
    MPI_Recv (&resultat_enfantd, 1, MPI_LONG_LONG, ENFANTD(numero), 1, MPI_COMM_WORLD,
&status);
    MPI_Recv (&resultat_enfantg, 1, MPI_LONG_LONG, ENFANTG(numero), 1, MPI_COMM_WORLD,
&status);
    resultat = numero + resultat_enfantg + resultat_enfantd;
    printf("Numero: %d envoi de %ld\n", numero, resultat);
    MPI_Send (&resultat, 1, MPI_LONG_LONG, PARENT(numero), 1, MPI_COMM_WORLD);
    MPI_Finalize ();
    return 0;
}
```