Module 6: Message Passing Interface
MPI

Historique

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Discuté lors d'un workshop à Williamsburg en avril 1992, planifié à Supercomputing en novembre 1992.
- Version préliminaire présentée à Supercomputing 1993.
- Version finale MPI 1.0 en juin 1994, plus de 80 personnes et 40 organisations ont été impliquées (vendeurs, universités, grands laboratoires...).
- MPI 1.1 en juin 1995
- MPI 2.0 (et MPI 1.2 comme sous-ensemble) en juillet 1997
- MPI 1.3 en mai 2008 (modifications finales).
- MPI 2.1 en juin 2008
- MPI 2.2 en septembre 2009.
- MPI 3.0 en septembre 2012, 3.1 en juin 2015 (mémoire partagée, assertions, sessions, MPI+thread/OpenCL, multi-langage, interface pour outils debug/prof).

Objectifs

ÉCOLE POLYTECHNIQUE MONTRÉAL

- API de programmation parallèle sur multi-ordinateur.
- Librairie pour gérer les communications.
- Bénéficie de l'expérience gagnée avec les systèmes antérieurs (PVM, LINDA).
- Ensemble cohérent de fonctions permettant une interface simple tout en s'assurant que l'implémentation sous-jacente puisse être efficace.
- Interopérabilité souhaitable avec OpenMP et OpenCL.
- Multiples fils d'exécution? Tolérance aux pannes?

Public cible

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Toutes les grandes grappes de calcul.
- Laboratoires gouvernementaux (modélisation météorologique ou nucléaire) ou industriels (analyse de réseaux de transmission chez Hydro-Québec, Modélisation par éléments finis chez Bombardier ou Andritz).
- Versions optimisées et outils offerts par les grands fournisseurs de matériel (Intel, IBM...).

Un premier programme

ÉCOLE POLYTECHNIQUE MONTRÉAL

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

int main( argc, argv )
int argc;
char **argv;
{
MPI_Init( &argc, &argv );
printf( "Hello world\n" );
MPI_Finalize();
return 0;
}

mpicc --mpilog --mpitrace -o hello hello.c

mpirun -np 2 hello
```

Fonctions de base

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Initialiser la librairie.
- Utiliser le communicateur par défaut MPI_COMM_WORLD.
- Demander le nombre d'éléments N et son rang (0 à N-1).
- Finaliser la librairie.
- Avec mpirun, le même programme s'exécute sur N noeuds mais chaque instance fait un travail différent en se basant sur son rang qui la différencie.

Contexte

ÉCOLE POLYTECHNIQUE MONTRÉAL

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

int main( argc, argv )
int argc;
char **argv;
{
int rank, size;
MPI_Init( &argc, &argv );
MPI_Comm_rank( MPI_COMM_WORLD, &rank );
MPI_Comm_size( MPI_COMM_WORLD, &size );
printf( "Hello world! I'm %d of %d\n",
        rank, size );
MPI_Finalize();
return 0;
}
```

Le contenu des messages

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Adresse, type des éléments et nombre, plutôt que adresse et nombre d'octets.
- Types définis récursivement pour représenter n'importe quelle structure de donnée.
- Permet de spécifier les données telles qu'elles sont.
- Minimise la possibilité d'erreur sur la longueur.
- Permet au système de faire les conversions si requis (e.g. petit ou gros boutien).

Les types MPI

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Primitifs: MPI_CHAR, MPI_UNSIGNED_CHAR (and SHORT, INT, LONG), MPI_FLOAT, MPI_DOUBLE, MPI_LONG_DOUBLE...
- Séquences: MPI_TYPE_CONTIGUOUS, MPI_TYPE_VECTOR, MPI_TYPE_HVECTOR, MPI_TYPE_INDEXED, MPI_TYPE_HINDEXED.
- Agrégation: MPI_TYPE_CREATE_STRUCT
- Calcul de la position: MPI_TYPE_COMMIT
- Divers: MPI_TYPE_FREE, MPI_GET_ADRESS, MPI_TYPE_CREATE_SUBARRAY, MPI_TYPE_CREATE_DARRAY, MPI_PACK, MPI_UNPACK

Description de types

ÉCOLE POLYTECHNIQUE MONTRÉAL

```
struct Element {
  unsigned temperature;
  double force[3];
  char status;
}

MPI_Datatype ElementType;

MPI_Datatype ElementFieldTypes[3] =
  {MPI_UNSIGNED, MPI_DOUBLE,MPI_CHAR};

int ElementFieldLength[3] = {1, 3, 1};

MPI_Aint ElementFieldPosition[3] =
  {0, sizeof(double), 4 * sizeof(double)};

MPI_Type_create_struct(3, ElementFieldLength,
ElementFieldPosition, ElementFieldTypes, &ElementType);
MPI_Type_commit(&ElementType);
```

Envoi de messages

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_SEND(buf, count, datatype, dest, tag, comm) bloque sur l'envoi d'un message à dest.
- MPI_RECV(buf, count, datatype, source, tag, comm, status) bloque sur l'attente d'un message de source avec tag ou MPI_ANY_SOURCE, MPI_ANY_TAG.
- MPI_SENDRECV(sendbuf, sendcount, sendtype, dest, sendtag, recvbuf, recvcount, recvtype, source, recvtag, comm, status) aller-retour comme pour un appel de procédure.
- MPI_SENDRECV_REPLACE(buf, count, datatype, dest, sendtag, source, recvtag, comm, status) échange de données.

Envois non bloquants

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_ISEND(buf, count, datatype, dest, tag, comm, request) l'envoi est demandé, buf ne doit plus être accédé jusqu'à ce que l'envoi soit terminé.
- MPI_IRECV(buf, count, datatype, source, tag, comm, request) la réception est demandée, buf ne peut être accédé avant que la réception ne soit terminée.
- MPI_WAIT(request, status), MPI_TEST(request, flag, status) ou MPI_REQUEST_GET_STATUS(request, flag, status) et MPI_REQUEST_FREE(request) permettent de savoir lorsque la requête est terminée.

Attente multiple

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_WAITANY(count, array_of_request, index, status), MPI_TESTANY(count, array_of_request, index, flag, status) permet d'attendre après une de plusieurs requêtes.
- MPI_WAITALL(count, array_of_request, array_of_status), MPI_TESTALL(count, array_of_request, flag, array_of_status) permet de vérifier toutes les requêtes.
- MPI_WAITSOME(incount, array_of_request, outcount, array_of_index, array_of_status), MPI_TESTSOME(count, array_of_request, array_of_index, array_of_status) permet de vérifier une ou plusieurs requêtes.

Autres fonctions sur les requêtes

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_PROBE(source, tag, comm, status), MPI_IPROBE(source, tag, comm, flag, status), attend ou vérifie si un message est disponible.
- MPI_CANCEL(request) annule une opération, MPI_TEST_CANCELLED(status, flag) permet de le vérifier.

Communications pré-définies

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_SEND_INIT(buf, count, datatype, dest, tag, comm, request), MPI_RECV_INIT(buf, count, datatype, source, tag, comm, request), spécifie les arguments pour un envoi/réception à venir, et à répéter.
- MPI_START(request), MPI_STARTALL(count, array_of_request), démarre la requête.

Autres types d'envoi

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_BSEND: buffered. Le contenu est copié avant d'être envoyé.
- MPI_SSEND: synchronous. Ne peut se compléter avant que le receveur ait commencé à recevoir le message.
- MPI_RSEND: ready, le receveur doit déjà être en attente du message. Ceci peut permettre de faire l'envoi en étant assuré qu'un tampon est prêt à l'autre bout.
- MPI_IBSEND, MPI_ISSEND, MPI_IRSEND, MPI_BSEND_INIT, MPI_SSEND_INIT, MPI_RSEND_INIT.

Gestion manuelle des tampons

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_BUFFER_ATTACH(buffer, size) spécifier manuellement l'espace à utiliser pour les tampons et conséquemment sa taille.
- MPI_BUFFER_DETACH(buffer, size).

Multiplication de matrice

ÉCOLE POLYTECHNIQUE MONTRÉAL

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

#define RA 62
#define CA 15
#define CB 7
#define ROOT 0
#define ROOT_A_FEUILE 1
#define FEUILLE_A_ROOT 2

int main (int argc, char *argv[])
{
  int size, rank, src, dest, mtype;
  int rangees, moyenne, extra, offset, i, j, k, rc;
  double a[RA][CA], b[CA][CB], c[RA][CB];
  MPI_Status status;

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

Multiplication de matrice

ÉCOLE POLYTECHNIQUE MONTRÉAL

```
if (rank == MASTER)
{ moyenne = RA / (size - 1); extra = RA % (size - 1);
  offset = 0; mtype = ROOT_A_FEUILLE;
  for (dest=1; dest<=(size - 1); dest++)
  { rangees = (dest <= extra) ? moyenne+1 : moyenne;
    MPI_Send(&offset,1,MPI_INT,dest,mtype,MPI_COMM_WORLD);
    MPI_Send(&rangees,1,MPI_INT,dest,mtype,MPI_COMM_WORLD);
    MPI_Send(&a[offset][0],rangees*CA,MPI_DOUBLE,dest,
        mtype, MPI_COMM_WORLD);
    MPI_Send(&b,CA*CB,MPI_DOUBLE,dest,mtype,
        MPI_COMM_WORLD);
    offset = offset + rangees;
  }
  mtype = FEUILLE_A_ROOT;
  for (i=1; i<=(size - 1); i++)
  { src = i;
    MPI_Recv(&offset,1,MPI_INT,src,mtype,MPI_COMM_WORLD,&status);
    MPI_Recv(&rangees,1,MPI_INT,src,mtype,MPI_COMM_WORLD,&status);
    MPI_Recv(&c[offset][0],rangees*CB,MPI_DOUBLE,src,mtype,
        MPI_COMM_WORLD,&status);
  }
}
```

Multiplication de matrice

ÉCOLE POLYTECHNIQUE MONTRÉAL

```
  if (rank > MASTER)
  { mtype = ROOT_A_FEUILLE;
    MPI_Recv(&offset,1,MPI_INT,ROOT,mtype,MPI_COMM_WORLD,&status);
    MPI_Recv(&rangees,1,MPI_INT,ROOT,mtype,MPI_COMM_WORLD,&status);
    MPI_Recv(&a,rangees*CA,MPI_DOUBLE,ROOT,mtype,MPI_COMM_WORLD,
&status);
    MPI_Recv(&b,CA*CB,MPI_DOUBLE,ROOT,mtype,MPI_COMM_WORLD,&status);
    for (k=0; k<CB; k++)
      for (i=0; i<rangees; i++)
      { c[i][k] = 0.0;
        for (j=0; j<CA; j++) c[i][k]=c[i][k]+a[i][j]*b[j][k];
      }
    mtype = FEUILLE_A_ROOT;
    MPI_Send(&offset,1,MPI_INT,ROOT,mtype,MPI_COMM_WORLD);
    MPI_Send(&rangees,1,MPI_INT,ROOT,mtype,MPI_COMM_WORLD);
    MPI_Send(&c,rangees*CB,MPI_DOUBLE,MASTER,mtype,MPI_COMM_WORLD);
  }
  MPI_Finalize();
}
```

Communications globales

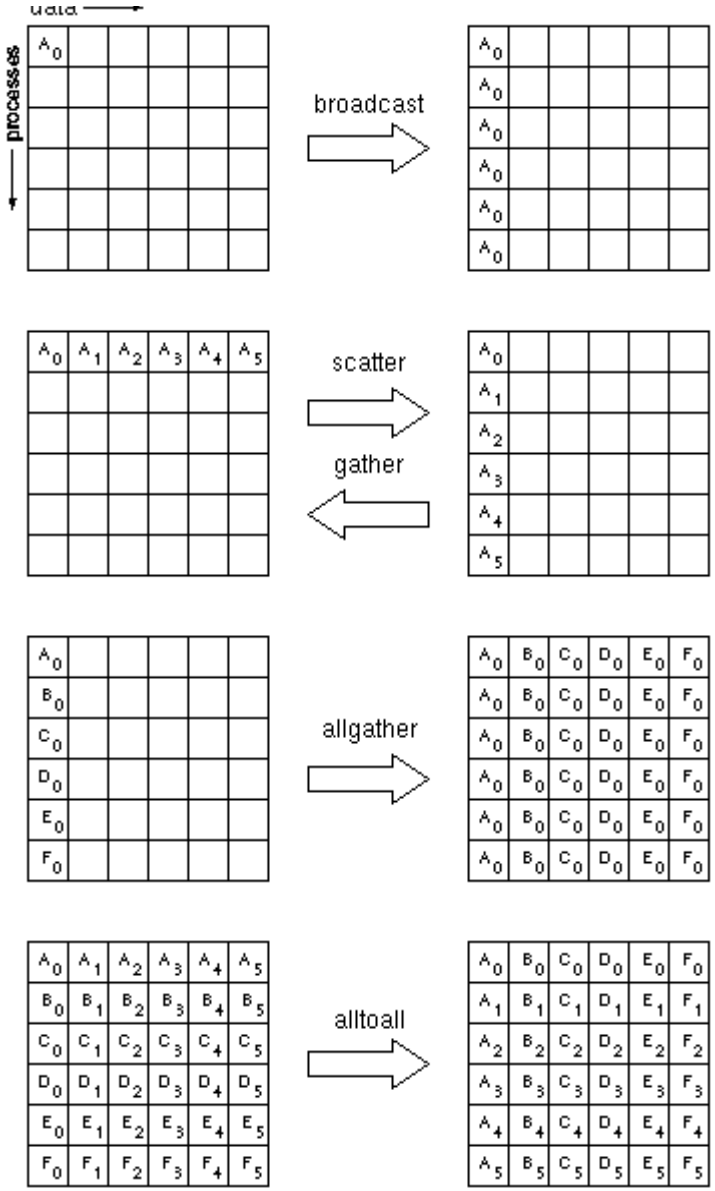

Communications globales

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_BARRIER(comm) bloque jusqu'à ce que tous les membres du groupe aient appelé cette fonction.
- MPI_BCAST(buffer, count, datatype, root, comm) est appelé par tous et le contenu de buffer sur le processus de rang root est copié à tous les autres.
- MPI_GATHER(sendbuf, sendcount, sendtype, recvbuf, recvcount, recvtype, root, comm) est équivalent à un send de chaque processus (incluant root) et à n receive de root avec l'adresse de réception calculée recvbuf + i * count.

Communications globales

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_SCATTER(sendbuf, sendcount, sendtype, recvbuf, recvcount, recvtype, root, comm) est équivalent à root qui fait n send de sendbuf + i * sendcount et chaque processus qui fait un receive.
- MPI_GATHERV, MPI_SCATTERV, viennent avec un vecteur de recvcount ou sendcount et un vecteur de positions afin de recevoir ou d'envoyer des messages de taille différente à une position variable.

De tous à tous

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_ALLGATHER(sendbuf, sendcount, sendtype, recvbuf, recvcount, recvtype, comm) est comme un gather excepté que tous les processus, il n'y a pas de root, recoivent toutes les informations. MPI_ALLGATHERV existe aussi.
- MPI_ALLTOALL(sendbuf, sendcount, sendtype, recvbuf, recvcount, recvtype, comm) chaque processus reçoit une partie de ce qui est envoyé par chaque autre. Le bloc j envoyé par le processus i est placé dans le bloc i du processus j. MPI_ALLTOALLV et MPI_ALLTOALLW existent aussi.

Réductions

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_REDUCE(sendbuf, recvbuf, count, datatype, op, root, comm) les éléments de chaque processus sont combinés ensemble dans l'élément correspondant du root avec l'opération qui peut être MAX, MIN, SUM, PROD, LAND, BAND, LOR, BOR, LXOR, BXOR, MAXLOC, MINLOC; MAXLOC and MINLOC notent le processus qui fournit l'élément maximal ou minimal. Il existe aussi MPI_ALLREDUCE qui retourne le résultat à tous.

Autres fonctions

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_REDUCE_SCATTER(sendbuf, recvbuf, recvcounts, datatype, op, comm) distribue les réductions selon le vecteur d'entier recvcounts.
- MPI_SCAN(sendbuf, recvbuf, count, datatype, op, comm), MPI_EXSCAN, effectuent une réduction avec préfixe inclusive (0 à i) ou exclusive (0 à i - 1).
- MPI_OP_CREATE(function, commute, op) permet de définir une opération en y associant une fonction. MPI_OP_FREE relâche l'opération créée.

Calcul de PI

ÉCOLE POLYTECHNIQUE MONTRÉAL

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

void srandom (unsigned seed);
double dboard (int darts);
#define DARTS 50000
#define ROUNDS 10
#define ROOT 0
int main (int argc, char *argv[])
{ double homepi, pi, avepi, pirecv, pisum;
  int rank, size, src, mtype, ret, i, n;
  MPI_Status status;

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

Calcul de PI

ÉCOLE POLYTECHNIQUE MONTRÉAL

```
  srandom (taskid);
  avepi = 0;
  for (i = 0; i < ROUNDS; i++) {
    homepi = dboard(DARTS);
    if (taskid != MASTER) {
      mtype = i;
      ret = MPI_Send(&homepi,1,MPI_DOUBLE, ROOT,mtype,MPI_COMM_WORLD);
    } else {
      mtype = i; pisum = 0;
      for (n = 1; n < size; n++) {
        ret = MPI_Recv(&pirecv, 1, MPI_DOUBLE, MPI_ANY_SOURCE,
                       mtype, MPI_COMM_WORLD, &status);
        pisum = pisum + pirecv;
      }
      pi = (pisum + homepi)/size;
      avepi = ((avepi * i) + pi)/(i + 1);
    }
  }
  MPI_Finalize();
  return 0;
}
```

Calcul de PI

```
  srandom (taskid);
  avepi = 0;

  for (i = 0; i < ROUNDS; i++) {
    homepi = dboard(DARTS);
    ret = MPI_Reduce(&homepi,&pisum,1,MPI_DOUBLE,MPI_SUM,ROOT,
        MPI_COMM_WORLD);
    if (taskid == MASTER) {
      pi = pisum/numtasks;
      avepi = ((avepi * i) + pi)/(i + 1);
    }
  }
  MPI_Finalize();
  return 0;
}
```

Groupes de communication

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_GROUP_SIZE(group, size), taille du groupe.
- MPI_GROUP_RANK(group, rank), position dans le groupe.
- MPI_GROUP_TRANSLATE_RANKS(group1, n, ranks1, group2, ranks2), pour chacun des n éléments du groupe 1 spécifiés dans ranks1, retourne le rang correspondant de group2 dans ranks2, ou MPI_UNDEFINED s'il ne s'y trouve pas.
- MPI_GROUP_COMPARE(group1, group2, result), compare les groupes pour voir si c'est le même ou s'ils ont les mêmes membres (IDENT, SIMILAR, UNEQUAL).

Sous-groupes

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_COMM_GROUP(comm, group) retourne le groupe du communicateur.
- MPI_GROUP_UNION(group1, group2, newgroup), MPI_GROUP_INTERSECTION, MPI_GROUP_DIFFERENCE combinent deux groupes pour en faire un nouveau.
- MPI_GROUP_INCL(group, n, ranks, newgroup), MPI_GROUP_EXCL, sélectionner des éléments à inclure ou exclure. RANGE_INCL et RANGE_EXCL existent aussi.

Autres fonctions

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_GROUP_FREE(group), libère le groupe
- MPI_COMM_COMPARE(comm1, comm2, result), vérifie si les communicateurs (listes de membres) sont identiques, similaires ou différents.
- MPI_COMM_DUP(comm, newcomm), copie le communicateur.
- MPI_COMM_CREATE(comm, group, newcomm), crée un communicateur à partir d'un groupe.
- MPI_COMM_SPLIT(comm, color, key, newcomm), crée un communicateur pour chaque groupe de processus avec la même couleur.

Attributs de Communicateurs

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_COMM_CREATE_KEYVAL(copy_fn, delete_fn, key, fn_data) réserve un code, key, pour un nouveau type d'attribut. les fonctions fn_copy et fn_delete sont appelées avec fn_data lorsque l'attribut est copié ou relâché.
- MPI_COMM_FREE_KEYVAL(key)
- MPI_COMM_SET_ATTR(comm, key, value), MPI_COMM_GET_ATTR(comm, key, val, flag), MPI_COMM_DELETE_ATTR(comm, key), ajoute, accède ou enlève un attribut sur un communicateur.

Intercommunications

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Communicateur entre deux groupes disjoints, local (inclut le processus courant) et remote (l'autre groupe).
- MPI_COMM_TEST_INTER(comm, flag), MPI_COMM_SIZE/GROUP/RANK, MPI_COMM_REMOTE_SIZE/GROUP
- MPI_INTERCOMM_CREATE(local_comm, local_leader, bridge_comm, remote_leader, tag, newintercomm) doit être appelé collectivement, bridge_comm est un groupe englobant dans lequel remote_leader est identifié.
- MPI_INTERCOMM_MERGE(intercomm, high, newintracomm)

Exemple d'intercommunicateur

ÉCOLE POLYTECHNIQUE MONTRÉAL

```
main(int argc, char **argv) {
  MPI_Comm   c, ic1, ic2;
  int mkey, rank;

  MPI_Init(&argc, &argv);
  MPI_Comm_rank(MPI_COMM_WORLD, &rank);
  mkey = rank % 3;
  MPI_Comm_split(MPI_COMM_WORLD, mkey, rank, &c);

  /* Nous avons trois sous-groupes g0, g1 et g2 en pipeline; g0 parle
     à g1 via 1 intercommunicateur, g1 parle à g0 et g2 et requiert 2
     intercommunicateurs, et g2 a un intercommunicateur vers g1. */
  if(mkey == 0) MPI_Intercomm_create(c,0,MPI_COMM_WORLD,1,1,&ic1);
  else if (mkey == 1)
   { MPI_Intercomm_create(c,0,MPI_COMM_WORLD,0,1,&ic1);
     MPI_Intercomm_create(c,0,MPI_COMM_WORLD,2,12,&ic2);
   }
  else MPI_Intercomm_create(c,0,MPI_COMM_WORLD,1,12,&ic1);
  ...

  MPI_Finalize();
}
```

Topologies cartésiennes

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_CART_CREATE(comm_old, ndims, dims, periods, reorder, comm_cart) crée un nouveau communicateur sur lequel il sera facile de connaître les voisins selon une grille à ndims dimensions (périodique, communication entre premier et dernier, ou non).
- MPI_DIMS_CREATE peut aider à choisir la grille.
- MPI_CARTDIM_GET, MPI_CART_GET, permettent d'interroger la structure de la grille.

Topologies cartésiennes

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_CART_RANK(coom, coords, rank), retourne le rank d'une coordonnée.
- MPI_CART_COORDS(comm, rank, maxdims, coords), retourne les coordonnées d'un rank.
- MPI_CART_SHIFT(comm, direction, disp, rank_source, rank_dest), calcule les voisins source et destination pour une communication d'un déplacement et direction (dimension) spécifiés.
- MPI_CART_SUB(comm, remain_dims, newcomm) crée un communicateur sur une topologie sur un sous-ensemble des dimensions.

Topologies de graphes

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_GRAPH_CREATE(comm_old, nnodes, index, edges, reorder, comm_graph), crée un nouveau communicateur pour lequel il est facile de savoir les voisins dans le graphe spécifié. Index dit où le trouve la dernière arête dans edges connectée au noeud correspondant.
- MPI_GRAPHDIMS_GET, MPI_GRAPH_GET, MPI_GRAPH_NEIGHBORS_COUNT, MPI_GRAPH_NEIGHBORS, permettent d'interroger la structure du graphe.
- MPI_TOPO_TEST(comm, status), savoir si cartésien, graphe ou aucun.

Récupération d'erreur

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_COMM_CREATE_ERRHANDLER(fn, errhandler), create a error handler from a pointer to function to call.
- MPI_COMM_SET_ERRHANDLER(comm, errhandler), associer une fonction de rappel en cas d'erreur lors d'un appel impliquant une communication.
- MPI_COMM_GET_ERRHANDLER, MPI_ERRHANDLER_FREE...

Autres fonctions

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI_PROCESSOR_NAME(name, resultlen), nom du noeud.
- MPI_WTIME() retourne le temps en secondes, double précision.
- MPI_WTICK() retourne la résolution du temps en secondes, double précision (e.g. .001s).

Analyse de performance

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Pour chaque fonction MPI, par exemple MPI_FONCTION, le vrai nom est MPI_PFONCTION et un symbole faible MPI_FONCTION est ajouté (e.g. #pragme weak MPI_SEND = PMPI_SEND). On peut donc remplacer MPI_FONCTION par une version qui collecte des statistiques et appelle MPI_PFONCTION à l'interne.
- MPI_PCONTROL(level), choisir le niveau de profilage.

Optimisation

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Utiliser tous les noeuds, tout le temps (choisir la granularité, équilibrer la charge).
- Réduire la communication (grouper les messages, recalculer, garder des copies).
- Eviter les copies de données (e.g. BSend, données non contiguës).
- RECV avant SEND, communications asynchrones en parallèle avec le calcul.
- Requêtes réutilisées, éviter la scrutation...

Outils d'analyse de performance

ÉCOLE POLYTECHNIQUE MONTRÉAL

- Tracer tous les envois de message et blocages associés. Obtenir un profil des temps d'exécution.
- VampirTrace est gratuit mais le visualisateur, Vampir, est commercial.
- MPE/Jumpshot (Argonne National Lab), TAU (UofOregon, Los Alamos National Lab), Paraver (Barcelona Supercomputing Center)
- Oracle Studio Performance Analyzer.

Conclusion

ÉCOLE POLYTECHNIQUE MONTRÉAL

- MPI est relativement simple (librairie) et mature, les grappes de noeuds n'ont pas changé aussi vite que les multi-processeurs.
- Il n'existe plus beaucoup d'équivalent en compétition (PVM, LINDA).
- La mise à l'échelle est cruciale avec les problèmes de taille monstrueuse et des grappes de milliers de noeuds.
- Pour certaines applications, Hadoop et Spark peuvent être considérés comme des alternatives.