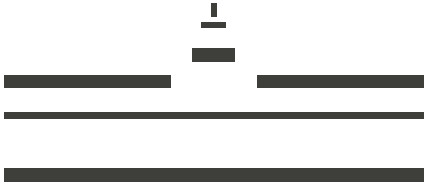

Westfälische
Wilhelms-Universität
Münster

Exkurs: Paralleles Rechnen

wissen.leben
WWU Münster

Christian Engwer

Konzepte für Parallelrechner

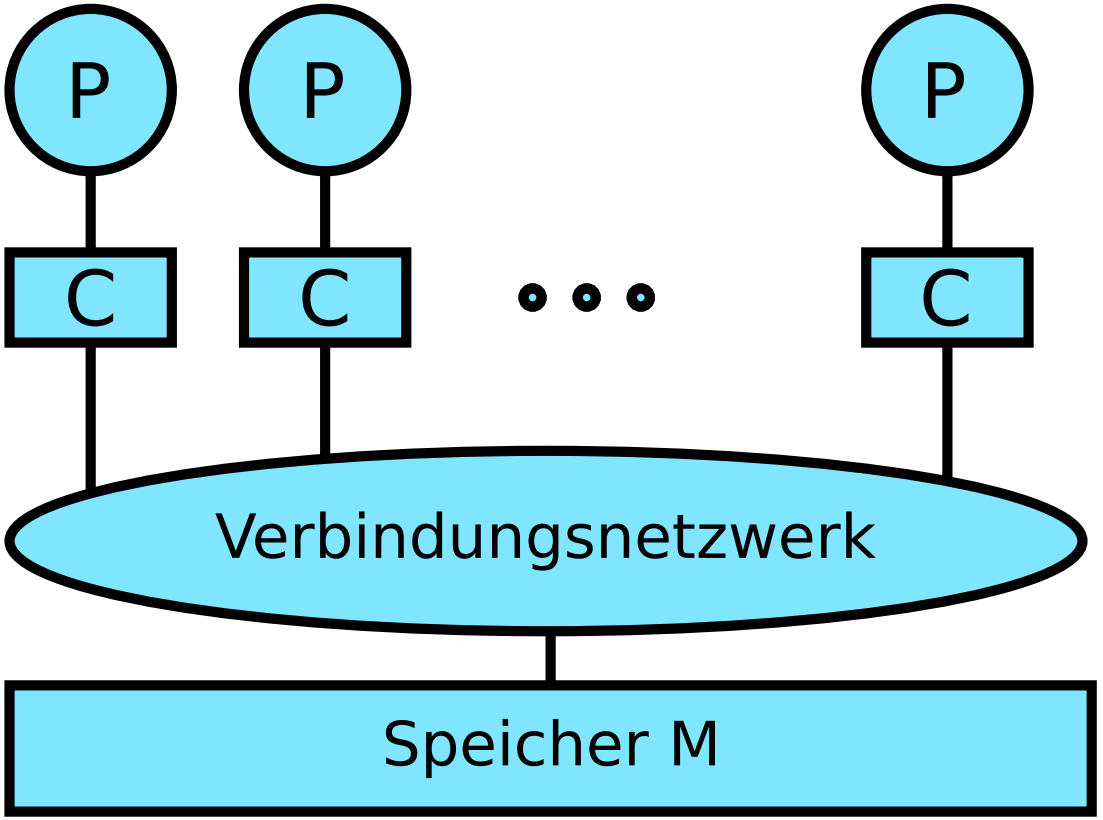

- *Gemeinsamer Speicher*
- Verteilter Speicher

Konzepte für Parallelrechner

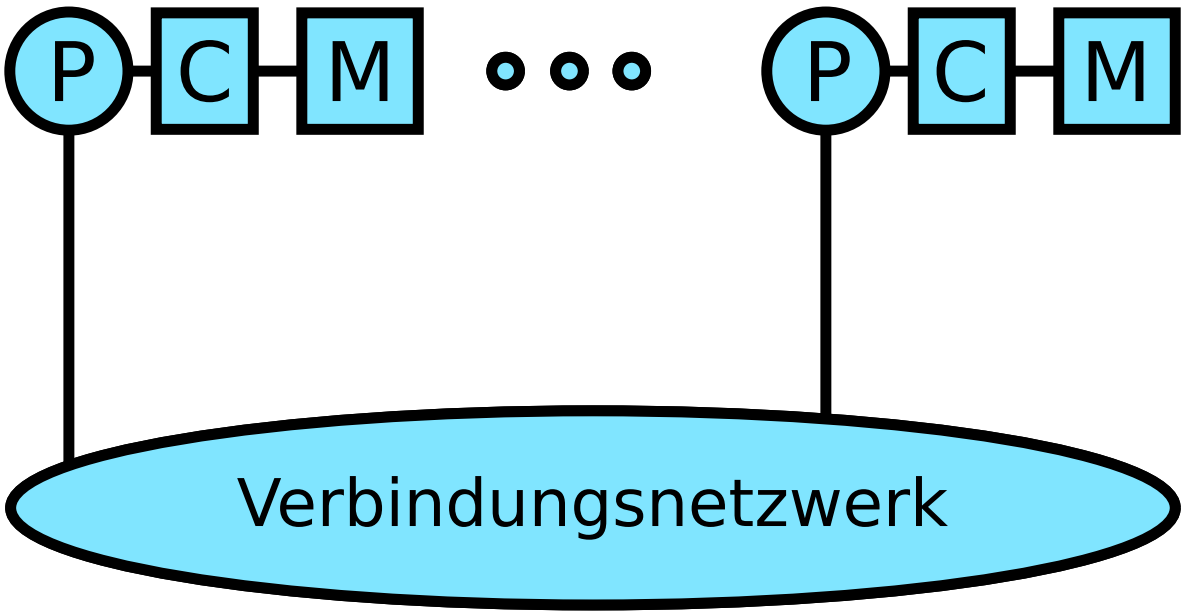

- Gemeinsamer Speicher
- *Verteilter Speicher*

MPI: Message Passing Interface

- Portable Bibliothek zum Nachrichtenaustausch
- Wurde 1993-94 durch ein intern. Gremium entwickelt
- 1997 wurde der Standard überarbeitet (MPI2)
- Open-Source Implementieren gibt beispielweise von: **MPICH**[1] und **OpenMPI**[2]
- Eigenschaften von MPI:
  - Direkte Anbindung an C, C++ und Fortran
  - verschiedene Arten von Punkt-zu-Punkt Kommunikation
  - globale Kommunikation
  - Daten Umwandlung in heterogenen Systemen
  - Virtuelle Netze & Topologien möglich

[1] http://www-unix.mcs.anl.gov/mpi/mpich

[2] http://www.open-mpi.org/

Hello World

```
1 #include <mpi.h>
  #include <unistd.h>
3 #include <iostream>

5 int main(int argc, char **argv)
  {
7   int *buf, i, rank, nints, len;
    char hostname[256];
9
    MPI_Init(&argc,&argv);
11  MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    gethostname(hostname,255);
13  std::cout << "Hello world!  I am process number: " << rank
              << " on host " << hostname << std::endl;
15  MPI_Finalize();
    return 0;
17 }
```

Kompilieren eines Programms

- Das Beispiel ist im SPMD-Stil geschrieben; der MPI Standard legt dies nicht fest und man kann auch andere Paradigmen verwenden.
- Kompilieren eines MPI C-Programmes und starten mit 8 Prozessen:

```
mpicc -o hello hello.c
mpirun -machinefile machines -np 8 hello
```

  Die Liste der Computer steht in der Datei machines.

  Für C++ Programme heisst der Compiler

```
mpicxx -o hello hello.cc
```

Initialisierung und Beenden

Bevor irgend ein MPI Befehl aufgerufen werden darf, muss MPI mit `MPI_Init` initialisiert werden, damit MPI das parallele Programm starten kann.

```
int MPI_Init(int *argc, char ***argv)
```

Nach dem letzten MPI Aufruf wird `MPI_Finalize` ausgeführt, um alles Prozesse ordentlich zu beenden.

```
int MPI_Finalize(void)
```

Kommunikator

MPI erlaubt es Kommunikation auf einem Subset der gestarten Prozesse durchzuführen, indem *virtuelle* Netzwerke, sogenannte Kommunikatoren, angelegt werden.

- `MPI_Comm` beschreibt einen Kommunikator, eine Menge von Prozessen $\{0, \ldots, P-1\}$.
- Des vordefinierte Netzwerk `MPI_COMM_WORLD` enthält alle gestarten Prozesse.
- *Virtuelle Topologien:* Ein Kommunikator kann zusätzlich eine spezielle Struktur erhalten, z.B. ein mehrdimensionales Feld, oder ein allgemeiner Graph.
- *Kontext:* Jeder Kommunikator definiert seinen eigenen Kommunikationskontext.

Rank und Size

Die Anzahl der Prozesse in einem Kommunikator wird mit `MPI_Comm_size` bestimmt:

```
int MPI_Comm_size(MPI_Comm comm, int *size)
```

Innerhalb eines Kommunikators hat jeder Prozess eine eindeutige Nummer, diese wird mit `MPI_Comm_rank` bestimmt:

```
int MPI_Comm_rank(MPI_Comm comm, int *rank)
```

Beispiel (I)

```
1 #include <stdio.h>
  #include <string.h>
3 #include <unistd.h>
  #include <mpi.h>  // provides MPI macros and functions
5
  int main (int argc, char *argv[])
7 {
    int my_rank;
9   int P;
    int dest;
11  int source;
    int tag=50;
13  char hostname[256];
    MPI_Status status;
15
    MPI_Init(&argc,&argv);  // begin of every MPI program
17  MPI_Comm_size(MPI_COMM_WORLD,&P);        // number of processes
    MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);  // my process number
19  gethostname(hostname,255);
```

Beispiel (II)

```
20
    // number of current process always between 0 and P-1
22  if (my_rank!=0) {
      dest = 0;
24    MPI_Send(hostname,strlen(hostname)+1,MPI_CHAR, // Send data
               dest,tag,MPI_COMM_WORLD);             // (blocking)
26  }
    else {
28    for (source=1; source<P; source++)
      {
30      MPI_Recv(hostname,256,MPI_CHAR,source,tag, // Receive data
                 MPI_COMM_WORLD,&status);          // (blocking)
32      std::cout << "Reveived␣a␣message␣from␣process␣" << source
                  << "␣on␣machine␣" << hostname << std::endl;
34    }
    }
36
    MPI_Finalize();  // end of every MPI program
38  return 0;
}
```

Ausgabe des Beispielprogramms (mit P=8)

```
> mpirun -machinefile machines -np 8 ./mpi-name
Reveived a message from process 1 on machine SCHAF03
Reveived a message from process 2 on machine SCHAF05
Reveived a message from process 3 on machine SCHAF07
Reveived a message from process 4 on machine SCHAF11
Reveived a message from process 5 on machine SCHAF13
Reveived a message from process 6 on machine SCHAF14
Reveived a message from process 7 on machine SCHAF15
```

Blockierende Kommunikation

Die Entsprechung zu **send** und **recv** bieten

```
1  int MPI_Send(void *message, int count, MPI_Datatype dt,
               int dest, int tag, MPI_Comm comm);
3  int MPI_Recv(void *message, int count, MPI_Datatype dt,
               int src, int tag, MPI_Comm comm,
5              MPI_Status *status);
```

Die ersten drei Parameter `message`, `count` und `dt` beschreiben die eigentlichen Daten. `message` ist ein Zeiger auf ein Feld mit `count` Elementen des Typs `dt`. Die Angabe des Datentyps erlaubt die automatische Umwandlung durch MPI. Die Parameter `dest`, `tag` und `comm` beschreiben das Ziel bzw. die Quelle der Nachricht.

Blockierende Kommunikation

Die Entsprechung zu **send** und **recv** bieten

```
1  int MPI_Send(void *message, int count, MPI_Datatype dt,
               int dest, int tag, MPI_Comm comm);
3  int MPI_Recv(void *message, int count, MPI_Datatype dt,
               int src, int tag, MPI_Comm comm,
5              MPI_Status *status);
```

Die ersten drei Parameter `message`, `count` und `dt` beschreiben die eigentlichen Daten. `message` ist ein Zeiger auf ein Feld mit `count` Elementen des Typs `dt`. Die Angabe des Datentyps erlaubt die automatische Umwandlung durch MPI. Die Parameter `dest`, `tag` und `comm` beschreiben das Ziel bzw. die Quelle der Nachricht.
MPI bietet verschiedene Varianten von `MPI_Send` (`MPI_BSend`, `MPI_SSend`, `MPI_RSend`), die wir aber jetzt nicht weiter diskutieren wollen.

Blockierende Kommunikation

Die Entsprechung zu **send** und **recv** bieten

```
1  int MPI_Send(void *message, int count, MPI_Datatype dt,
               int dest, int tag, MPI_Comm comm);
3  int MPI_Recv(void *message, int count, MPI_Datatype dt,
               int src, int tag, MPI_Comm comm,
5              MPI_Status *status);
```

Die ersten drei Parameter `message`, `count` und `dt` beschreiben die eigentlichen Daten. `message` ist ein Zeiger auf ein Feld mit `count` Elementen des Typs `dt`. Die Angabe des Datentyps erlaubt die automatische Umwandlung durch MPI. Die Parameter `dest`, `tag` und `comm` beschreiben das Ziel bzw. die Quelle der Nachricht.
MPI bietet verschiedene Varianten von `MPI_Send` (`MPI_BSend`, `MPI_SSend`, `MPI_RSend`), die wir aber jetzt nicht weiter diskutieren wollen.
`MPI_ANY_SOURCE` und `MPI_ANY_TAG` können verwendet werden, um belibige Nachrichten zu empfangen. Damit enthält `MPI_Recv` die Funktionalität von **recv_any**.

Datenumwandlung

MPI erlaubt die Verwendung in heterogenen Netzen. Hierbei ist es nötig manche Daten an die Darstellung auf der fremden Architektur anzupassen.

MPI definiert die architektur-unabhängigen Datentypen:

MPI_CHAR, MPI_UNSIGNED_CHAR, MPI_BYTE
MPI_SHORT, MPI_INT, MPI_LONG, MPI_LONG_LONG_INT,
MPI_UNSIGNED, MPI_UNSIGNED_SHORT, MPI_UNSIGNED_LONG,
MPI_FLOAT, MPI_DOUBLE and MPI_LONG_DOUBLE.

Der MPI Datentyp `MPI_BYTE` wird *nie* konvertiert.

Status

```
1   typedef struct {
        int count;
3       int MPI_SOURCE;
        int MPI_TAG;
5       int MPI_ERROR;
    } MPI_Status;
```

`MPI_Status` ist ein zusammengesetzter Datentyp, der Informationen über die Anzahl der empfangenen Objekte, den Quellprozess, das Tag und den Fehlerstatus enhält.

Guard Funktion

Die Guard Funktion **rprobe** liefert

```
int MPI_Iprobe(int source, int tag, MPI_Comm comm,
2               int *flag, MPI_Status *status);
```

Es ist eine nicht-blockierende Funktion, die überprüft, ob eine Nachricht vorliegt. `flag` erhält den Wert `true` ($\neq$ 0) wenn eine Nachricht mit passendem `source` und `tag` empfangen werden kann. Auch hier können `MPI_ANY_SOURCE` und `MPI_ANY_TAG` verwendet werden.

Non-blocking Communication

Die Funktionen **asend** und **arecv** bietet MPI als

```
int MPI_ISend(void *buf, int count, MPI_Datatype dt,
              int dest, int tag, MPI_Comm comm,
              MPI_Request *req);
int MPI_IRecv(void *buf, int count, MPI_Datatype dt,
              int src, int tag, MPI_Comm comm,
              MPI_Request *req);
```

`MPI_Request` speichert den Status einer Kommunikation, wie unsere **msgid**.

MPI_Request-Objekte

Der Status einer Nachricht kann mit Hilfe der `MPI_Request`-Objekte und folgender Funktion geprüft werden:

```
int MPI_Test(MPI_Request *req, int *flag,
             MPI_Status *status);
```

`flag` wird auf `true` ($\neq$ 0) gesetzt, wenn die Kommunikation, die `req` beschreibt abgeschlossen ist. In diesem Fall enthält `status` weitere Informationen.

Globale Kommunikation

MPI bietet ebenfalls Funktionen zur globalen Kommunikation, welche alle Prozesse eines Kommunikators einschließen.

```
int MPI_Barrier(MPI_Comm comm);
```

implementiert eine Barriere; alle Prozesse werden blockiert, bis der letzte Prozess die Funktion ausgeführt hat.

```
1 int MPI_Bcast(void *buf, int count, MPI_Datatype dt,
                int root, MPI_Comm comm);
```

verteilt eine Nachricht an alle Prozesse eine Kommunikators (Einer-an-Alle Kommunikation).

Einsammeln von Daten

MPI hat eine Reihe verschiedener Funktionen um Daten von verschiedenen Prozessen einzusammeln. Z.B:

```
int MPI_Reduce(void *sbuf, void *rbuf, int count,
2               MPI_Datatype dt, MPI_Op op, int root,
                MPI_Comm comm);
```

kombiniert die Daten im Sende-Puffer `sbuf` aller Prozesse durch die assoziative Operation `op` (z.B. `MPI_SUM`, `MPI_MAX` oder `MPI_MIN`). Das Ergebnis erhält der Prozesse `root` in seinen Empfang-Puffer `rbuf`.

Zeitmessung

MPI bietet direkt Funktionen zur Zeitmessung:

```
1    double MPI_Wtime();
```

Der Rückgabewert sind Sekunden seit einem „beliebigen” Zeitpunkt in der Vergangenheit. Die Zeit für eine spezielle Operation läßt sich also mit

```
1    double start = MPI_Wtime();
     expensive_funktion();
3    std::cout << "elapsed time = "
               << MPI_Wtime() - start << std::endl;
```

bestimmen.

Weitere Informationen

- *MPI: Dokumentation der verschiedenen Message-Passing Interface Standards*
  http://www.mpi-forum.org/docs/
- *MPICH-A Portable Implementation of MPI*
  http://www-unix.mcs.anl.gov/mpi/mpich
- *Open MPI: Open Source High Performance Computing*
  http://www.open-mpi.org/
- *Liste von MPI Tutorials*
  http://www-unix.mcs.anl.gov/mpi/tutorial/