Distributed-Memory Programmiermodelle II

Stefan Lang

Interdisziplinäres Zentrum für Wissenschaftliches Rechnen
Universität Heidelberg
INF 368, Raum 532
D-69120 Heidelberg
phone: 06221/54-8264
email: Stefan.Lang@iwr.uni-heidelberg.de

WS 12/13

Distributed-Memory Programmiermodelle II

Kommunikation über Nachrichtenaustausch

- MPI Standard
- Globale Kommunikation auf verschiedenen Topologien
  - Feld (1D / 2D / 3D)
  - Hypercube
- Lokaler Austausch

MPI: Einführung

Das *Message Passing Interface* (MPI) ist eine portable Bibliothek von Funktionen zum Nachrichtenaustausch zwischen Prozessen.

- MPI wurde 1993/94 von einem internationalen Gremium entworfen.
- Ist auf praktisch allen Plattformen verfügbar, inklusive der freien Implementierungen MPICH und LAM.
- Merkmale:
  - Bibliothek zum Binden mit C-, C++- und FORTRAN-Programmen (keine Spracherweiterung).
  - Große Auswahl an Punkt-zu-Punkt Kommunikationsfunktionen.
  - Globale Kommunikation.
  - Datenkonversion für heterogene Systeme.
  - Teilmengenbildung und Topologien.
- MPI besteht aus über 125 Funktionen, die auf über 200 Seiten im Standard beschrieben werden. Daher können wir nur eine kleine Auswahl der Funktionalität betrachten.
- MPI-1 hat keine Möglichkeiten zur dynamischen Prozesserzeugung, dies ist in MPI-2 möglich, ebenso Ein-/Ausgabe.

MPI: Hello World

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

int main (int argc, char *argv[])
{
    int my_rank, P;
    int dest, source;
    int tag=50;
    char message[100];
    MPI_Status status;

    MPI_Init(&argc,&argv);
    MPI_Comm_size(MPI_COMM_WORLD,&P);
    MPI_Comm_rank(MPI_COMM_WORLD,&my_rank);

    if (my_rank!=0)
    {
        sprintf(message,"I am process %d\n",my_rank);
        dest = 0;
        MPI_Send(message,strlen(message)+1,MPI_CHAR,
                 dest,tag,MPI_COMM_WORLD);
    }
    else
    {
        puts("I am process 0\n");
        for (source=1; source<P; source++)
        {
            MPI_Recv(message,100,MPI_CHAR,source,tag,
                     MPI_COMM_WORLD,&status);
            puts(message);
        }
    }
    MPI_Finalize();

    return 0;
}
```

- SPMD-Stil!
- Übersetzen und starten geht mit

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

- `machines` enthält Namen der zu benutzenden Rechner.

MPI: Blockierende Kommunikation I

- MPI unterstützt verschiedene Varianten blockierender und nicht-blockierender Kommunikation, Wächter für die **receive**-Funktion, sowie Datenkonversion bei Kommunikation zwischen Rechnern mit unterschiedlichen Datenformaten.
- Die grundlegenden blockierenden Kommunikationsfunktionen lauten:

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

- Eine Nachricht in MPI besteht aus den eigentlichen *Daten* und einer Hülle (*engl.* envelope).
- Die Daten sind immer ein Array von elementaren Datentypen. Dies erlaubt MPI eine Datenkonversion vorzunehmen.

MPI: Blockierende Kommunikation II

- Die Hülle besteht aus:
  1. Nummer des Senders,
  2. Nummer des Empfängers,
  3. Tag,
  4. und einem Communicator.
- Nummer des Senders und Empfängers wird als Rank bezeichnet.
- Tag ist auch eine Integer-Zahl und dient der Kennzeichnung verschiedener Nachrichten zwischen identischen Kommunikationspartnern.
- Ein Communicator ist gegeben durch eine Teilmenge der Prozesse und einen Kommunikationskontext. Nachrichten, die zu verschiedenen Kontexten gehören, beeinflussen einander nicht, bzw. Sender und Empfänger müssen den selben Communicator verwenden.
- Zunächst verwenden wir nur den Default Communicator `MPI_COMM_WORLD` (alle gestarteten Prozesse).

MPI: Blockierende Kommunikation III

- `MPI_Send` ist grundsätzlich blockierend, es gibt jedoch diverse Varianten:
  - *buffered send* (B): Falls der Empfänger noch keine korrespondierende **recv**-Funktion ausgeführt hat, wird die Nachricht auf Senderseite gepuffert. Ein „buffered send“ wird, genügend Pufferplatz vorausgesetzt, immer sofort beendet. Im Unterschied zur asynchronen Kommunikation kann der Sendepuffer `message` sofort wiederverwendet werden.
  - *synchronous send* (S): Ende des synchronous send zeigt an, dass der Empfänger eine **recv**-Funktion ausführt und begonnen hat, die Daten zu lesen.
  - *ready send* (R): Ein ready send darf nur ausgeführt werden, falls der Empfänger bereits das korresponierende **recv** ausgeführt hat. Ansonsten führt der Aufruf zum Fehler.
- Die entsprechenden Aufrufe lauten `MPI_Bsend`, `MPI_Ssend` und `MPI_Rsend`.
- Der `MPI_Send`-Befehl hat entweder die Semantik von `MPI_Bsend` oder `MPI_Ssend`, je nach Implementierung. `MPI_Send` kann also, muss aber nicht blockieren. In jedem Fall kann der Sendepuffer `message` sofort nach beenden wieder verwendet werden.

MPI: Blockierende Kommunikation IV

- Der Befehl `MPI_Recv` ist in jedem Fall blockierend.
- Das Argument `status` enthält Quelle, Tag, und Fehlerstatus der empfangenen Nachricht.
- Für die Argumente `src` und `tag` können die Werte `MPI_ANY_SOURCE` bzw. `MPI_ANY_TAG` eingesetzt werden. Somit beinhaltet `MPI_Recv` die Funktionalität von **recv_any**.
- Eine nicht-blockierende Wächterfunktion für das Empfangen von Nachrichten steht mittels

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

zur Verfügung.

MPI: Nichtblockierende und globale Kommunikation I

- Für nichtblockierende Kommunikation stehen die Funktionen

```
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);
```

  zur Verfügung.
- Mittels der `MPI_Request`-Objekte ist es möglich, den Zustand des Kommunikationsauftrages zu ermitteln (entspricht unserer **msgid**).
- Dazu gibt es (unter anderem) die Funktion

```
int MPI_Test(MPI_Request *req, int *flag, MPI_Status
```

- Das `flag` wird auf `true` ($\neq 0$) gesetzt, falls die durch `req` bezeichnete Kommunikationsoperation abgeschlossen ist. In diesem Fall enthält `status` Angaben über Sender, Empfänger und Fehlerstatus.

  Zu beachten ist dabei, dass das `MPI_Request`-Objekt ungültig wird, sobald `MPI_Test` mit `flag==true` zurückkehrt. Es darf dann nicht mehr verwendet werden.

MPI: Nichtblockierende und globale Kommunikation II

- Für die globale Kommunikation stehen zur Verfügung (u. a.):

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

  blockiert alle Prozesse eines Communicators bis alle da sind.

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

  verteilt die Nachricht in Prozess `root` an alle anderen Prozesse des Communicator.

- Für das Einsammeln von Daten stehen verschiedene Operationen zur Verfügung. Wir beschreiben nur eine davon:

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

  kombiniert die Daten im Eingangspuffer `sbuf` aller Prozesse mittels der assoziativen Operation `op`. Das Endergebnis steht im Empfangspuffer `rbuf` des Prozesses `root` zur Verfügung. Beispiele für `op` sind `MPI_SUM`, `MPI_MAX`.


  ```

Alle-an-alle: 1D Feld, Prinzip

Jeder will ein Datum an alle schicken (Variante: Akkumulieren mit assoziativem Operator):

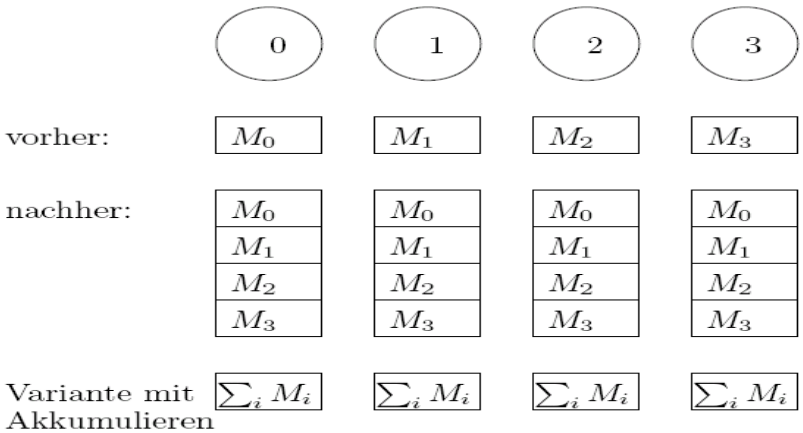

Ring lassen wir weg und gehen gleich zum 1D-Feld: Jeder schickt in beide Richtungen.

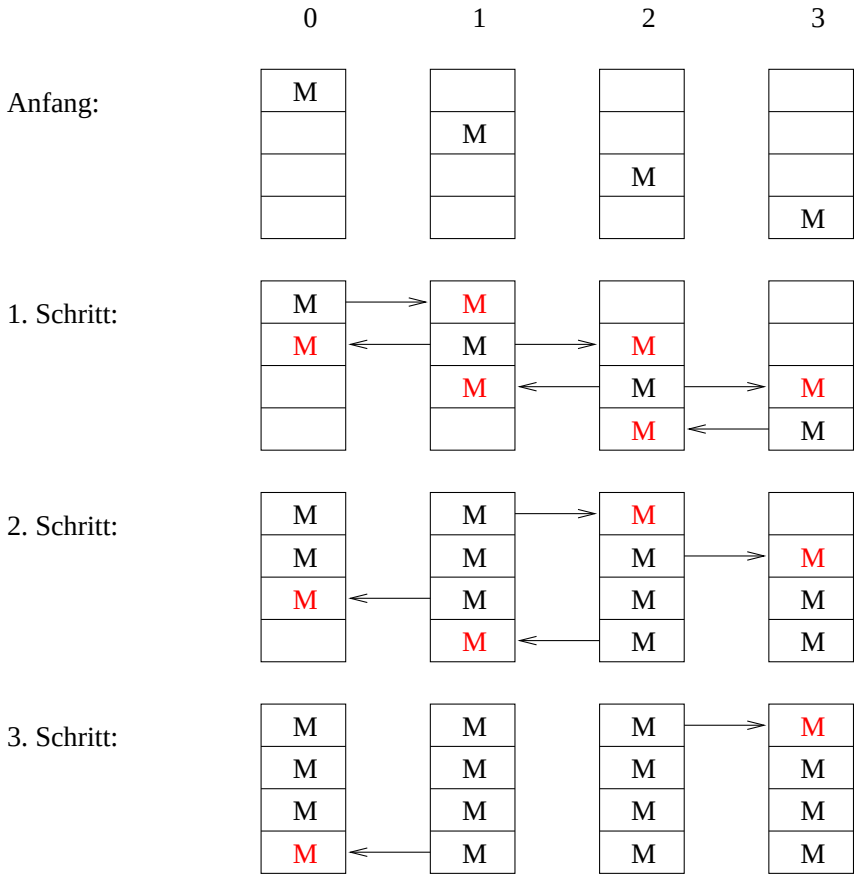

Wir verwenden synchrone Kommunikation. Entscheide Wer sendet/empfängt durch schwarz-weiß Färbung:

Alle-an-alle: 1D Feld, Code

Programm (Alle an alle auf 1D-Feld)

```
parallel all-to-all-1D-feld
{
    const int P;
    process Π[int p ∈ {0, ..., P − 1}]
    {
        void all_to_all_broadcast(msg m[P])
        {
            int i,
                from_left= p − 1, from_right= p + 1,
                                                    // das empfange ich
                to_left= p, to_right= p;            // das verschicke ich
            for (i = 1; i < P; i + +)               // P − 1 Schritte
            {
                if ((p%2) == 1)                     // schwarz/weiss Färbung
                {
                    if (from_left ≥ 0) recv(Π_{p−1}, m[from_left]);
                    if (to_right ≥ 0) send(Π_{p+1}, m[to_right]);
                    if (from_right < P) recv(Π_{p+1}, m[from_right]);
                    if (to_left < P) send(Π_{p−1}, m[to_left]);
                }
                else
                {
                    if (to_right ≥ 0) send(Π_{p+1}, m[to_right]);
                    if (from_left ≥ 0) recv(Π_{p−1}, m[from_left]);
                    if (to_left < P) send(Π_{p−1},m[to_left]);
                    if (from_right < P) recv(Π_{p+1}, m[from_right]);
                }
                ...
```

Alle-an-alle: 1D Feld, Code

Programm (Alle an alle auf 1D-Feld cont.)

```
parallel all-to-all-1D-feld cont.
{
                        ...

                        from_left−−; to_right−−;
                        from_right++; to_left++;
                    }
                }
                ...
                m[p] =„Das ist von p!“;
                all_to_all_broadcast(m);
                ...
        }
}
```

Alle-an-alle: 1D Feld, Laufzeit

- Für die Laufzeitanalyse betrachte P ungerade, $P = 2k + 1$:

$$\underbrace{\Pi_0, \ldots, \Pi_{k-1}}_{k}, \; \Pi_k, \; \underbrace{\Pi_{k+1}, \ldots, \Pi_{2k}}_{k}$$

Prozess Π_k			
	empfängt	k	von links
	schickt	$k+1$	nach rechts
	empfängt	k	von rechts
	schickt	$k+1$	nach links.
	$\sum =$	$4k+2$	
		$= 2P$	

- Danach hat Π_k alle Nachrichten. Nun muss die Nachricht von 0 noch zu $2k$ und umgedreht. Dies dauert nochmal

$$(\underbrace{k}_{\text{Entfernung}} - 1) \cdot \underbrace{2}_{\substack{\text{senden u.} \\ \text{empfangen}}} + \underbrace{1}_{\substack{\text{der Letzte} \\ \text{empfängt nur}}} = 2k - 1 = P - 2$$

also haben wir

$$T_{all-to-all-array-1d} = (t_s + t_h + t_w \cdot n)(3P - 2)$$

Alle-an-alle: Hypercube

Der folgende Algorithmus für den Hypercube ist als *Dimensionsaustausch* bekannt und wird wieder rekursiv hergeleitet.

Beginne mit $d = 1$:

Bei vier Prozessen tauschen erst 00 und 01 bzw 10 und 11 ihre Daten aus, dann tauschen 00 und 10 bzw 01 und 11 jeweils zwei Informationen aus

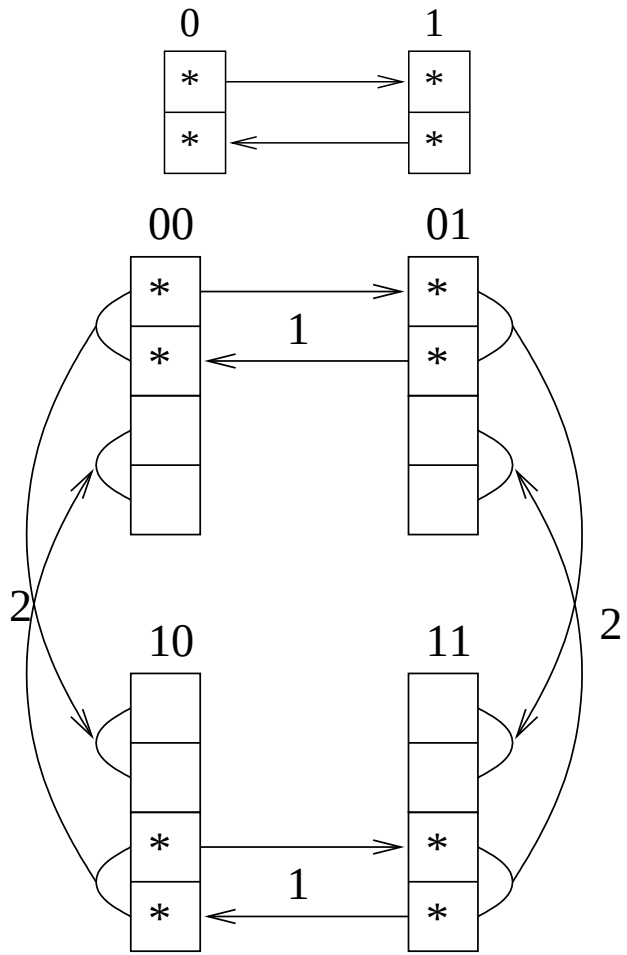

Alle-an-alle: Hypercube

- **void** *all_to_all_broadcast*(**msg** $m[P]$) {
  int i, $mask = 2^d - 1$, q;
  for ($i = 0$; $i < d$; $i++$) {
  $q = p \oplus 2^i$;
  if ($p < q$) { // wer zuerst?
  send(Π_q,$m[p\&mask]$,...,$m[p\&mask + 2^i - 1]$);
  recv(Π_q,$m[q\&mask]$,...,$m[q\&mask + 2^i - 1]$);
  }
  else {
  recv(Π_q,$m[q\&mask]$,...,$m[q\&mask + 2^i - 1]$);
  send(Π_q,$m[p\&mask]$,...,$m[p\&mask + 2^i - 1]$);
  }
  $mask = mask \oplus 2^i$;
  }
  }

- Laufzeitanalyse:

$$T_{all-to-all-bc-hc} = \underbrace{2}_{\substack{\text{send u.}\\ \text{receive}}} \sum_{i=0}^{\operatorname{ld} P-1} t_s + t_h + t_w \cdot n \cdot 2^i =$$

$$= 2 \operatorname{ld} P (t_s + t_h) + 2 t_w n (P-1).$$

- Für große Nachrichten hat der HC keinen Vorteil: Jeder muss n Worte von jedem empfangen, egal wie die Topologie aussieht.

Einer-an-alle indiv. Nachrichten: Hypercube, Prinzip

- Prozess 0 schickt an jeden eine Nachricht, aber an jeden eine andere!

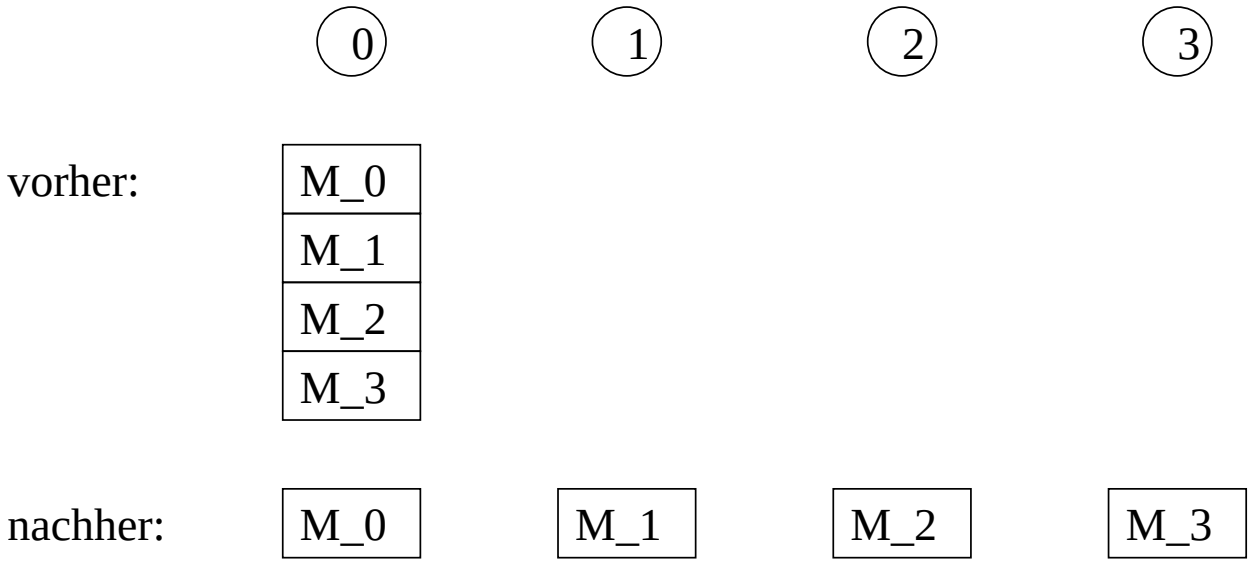

- Beispiel ist die Ein/Ausgabe in *eine* Datei.
- Der Abwechslung halber betrachten wir hier mal die Ausgabe, d.h. alle-an-einen mit persönlichen Nachrichten.
- Wir nutzen die altbekannte Hypercubestruktur:

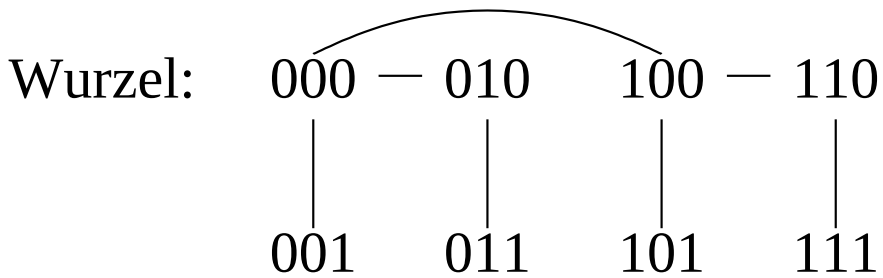

Einer-an-alle mit indiv. Nachrichten: Hypercube, Code

Programm (*Einsammeln* persönlicher Nachrichten auf dem Hypercube)

parallel *all-to-one-personalized*
{
const int $d, P = 2^d$;
process Π[**int** $p \in \{0, \ldots, P-1\}$]{
void *all_to_one_pers*(**msg** *m*) {
int *mask, i, q, root;*
// bestimme p's Wurzel: Wieviele Bits am Ende sind Null?
$mask = 2^d - 1$;
for $(i = 0; i < d; i++)$
{
$mask = mask \oplus 2^i$;
if $(p\&mask \neq p)$ **break**;
} // $p = p_{d-1} \ldots p_{i+1} \underbrace{1}_{\text{zuletzt 0 gesetzt in } mask} \underbrace{0 \ldots 0}_{i-1,\ldots,0}$
if $(i < d)$ $root = p \oplus 2^i$; // meine Wurzelrichtung

// eigene Daten
if $(p == 0)$ *selber-verarbeiten(m);*
else send(*root,m*); // hochgeben

. . .

}

Einer-an-alle mit indiv. Nachrichten: Hypercube, Code

Programm (*Einsammeln* persönlicher Nachrichten auf dem Hypercube cont.)

parallel *all-to-one-personalized cont.*

```
{
        ...

        // arbeite Unterbäume ab:
        mask = 2^d − 1;
        for (i = 0; i < d; i++) {
            mask = mask ⊕ 2^i; q = p ⊕ 2^i;
            if (p&mask == p)
```

// $p = \quad p_{d-1} \ldots p_{i+1} \quad 0 \quad \underbrace{0 \ldots 0}_{i-1,\ldots,0}$

// $q = \quad p_{d-1} \ldots p_{i+1} \quad 1 \quad \underbrace{0 \ldots 0}_{i-1,\ldots,0}$

// $\Rightarrow$ *ich bin Wurzel eines HC der Dim.* $i+1$*!*

```
                for (k = 0; k < 2^i; k++) {
                    recv(Π_q,m);
                    if (p == 0) verarbeite(m);
                    else send(Π_root,m);
                }
        }
    }
}
```

Einer-an-alle m. indiv. Nachrichten: Laufzeit, Varianten

Für die *Laufzeit* hat man für grosse (n) Nachrichten

$$T_{all-to-one-pers} \geq t_w n(P-1)$$

wegen dem Pipelining.

Einige Varianten sind denkbar:

- *Individuelle Länge der Nachricht:* Hier sendet man vor verschicken der eigentlichen Nachricht nur die Längeninformation (in der Praxis ist das notwendig $\rightarrow$ MPI).
- *beliebig lange Nachricht* (aber nur endlicher Zwischenpuffer!): zerlege Nachrichten in Pakete fester Länge.
- *sortierte Ausgabe:* Es sei jeder Nachricht M_i (von Prozess i) ein Sortierschlüssel k_i zugeordnet. Die Nachrichten sollen von Prozess 0 in aufsteigender Reihenfolge der Schlüssel verarbeitet werden, *ohne* dass alle Nachrichten zwischengepuffert werden.

Einer-an-alle m. indiv. Nachrichten: Laufzeit, Varianten

- Bei *sortierter Ausgabe* folgt man der folgenden Idee:

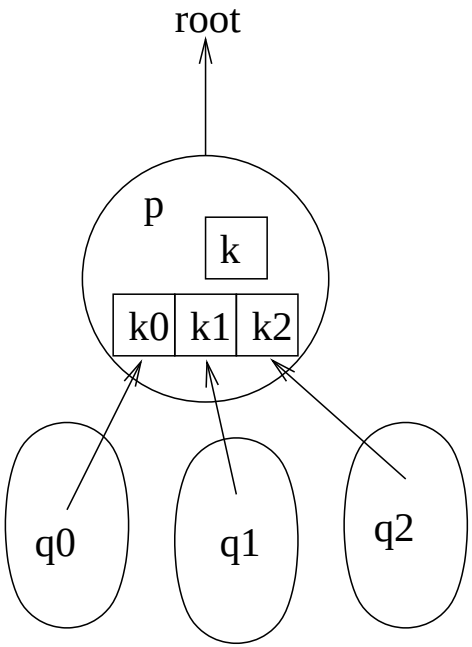

p habe drei „Untergebene“, q_0, q_1, q_2, die für ganze Unterbäume stehen.
Jeder q_i sendet seinen nächst kleinsten Schlüssel an p, der den kleinsten Schlüssel raussucht und ihn seinerseits, mitsamt der inzwischen übertragenen Daten, weitergibt.