Distributed-Memory Programmiermodelle I

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 13/14

Distributed-Memory Programmiermodelle I

Kommunikation über Nachrichtenaustausch

- Synchroner Nachrichtenaustausch
- Asynchroner Nachrichtenaustausch
- Globale Kommunikation bei
  - Store-and-Forward oder
  - Cut-Through Routing
- Globale Kommunikation auf verschiedenen Topologien
  - Ring
  - Feld (2D / 3D)
  - Hypercube

Synchroner Nachrichtenaustausch I

- Für den Nachrichtenaustausch benötigen wir mindestens zwei Funktionen:
  - **send**: Überträgt einen Speicherbereich aus dem Adressraum des Quellprozesses in das Netzwerk mit Angabe des Empfängers.
  - **recv**: Empfängt einen Speicherbereich aus dem Netzwerk und schreibt ihn in den Adressraum des Zielprozesses.
- Wir unterscheiden:
  - Zeitpunkt zu dem eine Kommunikationsfunktion beendet ist.
  - Zeitpunkt zu dem die Kommunikation wirklich stattgefunden hat.
- Bei synchroner Kommunikation sind diese Zeitpunkte identisch, d.h.
  - **send** blockiert bis der Empfänger die Nachricht angenommen hat.
  - **recv** blockiert bis die Nachricht angekommen ist.
- Syntax in unserer Programmiersprache:
  - **send**$(dest - process, expr_1, \ldots, expr_n)$
  - **recv**$(src - process, var_1, \ldots, var_n)$

Synchroner Nachrichtenaustausch II

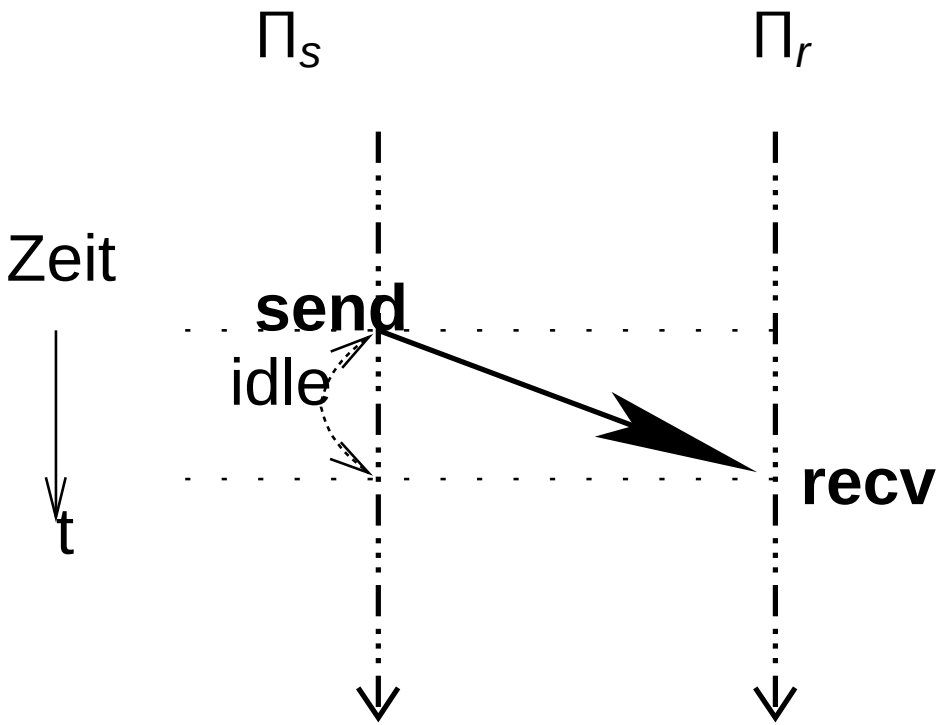

(a)

Π_1: **recv**(Π_3,i)
send(Π_2,i)

Π_2: **recv**(Π_1,i)
send(Π_3,i)

Π_3: **recv**(Π_2,i)
send(Π_1,i)

(b)

(a) Synchronisation zweier Prozesse durch ein **send**/**recv** Paar

(b) Beispiel für eine Verklemmung

Synchroner Nachrichtenaustausch III

Es gibt eine Reihe von Implementierungsmöglichkeiten.

- Senderinitiiert, *three-way handshake*:
  - Quelle Q schickt *ready-to-send* an Ziel Z.
  - Ziel schickt *ready-to-receive* wenn **recv** ausgeführt wurde.
  - Quelle überträgt Nachricht (variable Länge, single copy).
- Empfängerinitiiert, *two-phase protocol*:
  - Z schickt *ready-to-receive* an Q wenn **recv** ausgeführt wurde.
  - Q überträgt Nachricht (variable Länge, single copy).
- Gepuffertes Senden
  - Q überträgt Nachricht sofort, Z muss eventuell zwischenspeichern.
  - Hier stellt sich das Problem des endlichen Speicherplatzes!

Synchroner Nachrichtenaustausch IV

- Synchrones **send**/**recv** ist nicht ausreichend um alle Kommunikationsaufgaben zu lösen!
- Beispiel: Im Erzeuger-Verbraucher-Problem wird der Puffer als eigenständiger Prozess realisiert. In diesem Fall kann der Prozess nicht wissen mit welchem Erzeuger oder Verbraucher er als nächstes kommunizieren wird. Folglich kann ein blockierendes **send** zur Verklemmung führen.
- Lösung: Bereitstellung zusätzlicher *Wächterfunktionen*, die überprüfen ob ein **send** oder **recv** zur Blockade führen würde:
  - **int sprobe**(*dest* − *process*)
  - **int rprobe**(*src* − *process*).

  sprobe liefert 1 falls der Empfängerprozess bereit ist zu empfangen, d.h. ein **send** wird nicht blockieren:
  - **if** (**sprobe**(Π_d)) **send**(Π_d,...);

  Analog für **rprobe**.
- Wächterfunktionen blockieren nie!

Synchroner Nachrichtenaustausch V

- Man braucht nur eine der beiden Funktionen.
  - **rprobe** lässt sich leicht in das senderinitiierte Protokoll integrieren.
  - **sprobe** lässt sich leicht in das empfängerinitiierte Protokoll integrieren.
- Ein Befehl mit ähnlicher Wirkung wie **rprobe** ist:
  - **recv_any**(who,var_1,...,var_n).

  Er erlaubt das empfangen von einem *beliebigen* Prozess, dessen ID in der Variablen *who* abgelegt wird.
- **recv_any** wird am einfachsten mit dem senderinitiierten Protokoll implementiert.

Asynchroner Nachrichtenaustausch I

- Befehle zum asynchronen Nachrichtenaustausch:
  - **asend**($dest-process$,$expr_1$,...,$expr_n$)
  - **arecv**($src-process$, var_1,..., var_n)
- Hier zeigt das Beenden der Kommunikationsfunktion *nicht* an, dass die Kommunikation tatsächlich stattgefunden hat. Dies muss mit extra Funktionen erfragt werden.
- Man stellt sich vor, es wird ein *Auftrag* an das System gegeben die entsprechende Kommunikation durchzuführen, sobald sie möglich ist. Der Rechenprozess kann währenddessen andere Dinge tun (*communication hiding*).
- Syntax:
  - **msgid asend**($dest-process$,var_1,...,var_n)
  - **msgid arecv**($src-process$,var_1,...,var_n)

  blockieren nie! **msgid** ist eine Quittung für den Kommunikationsauftrag.

Asynchroner Nachrichtenaustausch II

- Vorsicht: Die Variablen $var_1, \ldots, var_n$ dürfen nach Absetzen des Kommunikationsbefehls nicht mehr modifiziert werden!
- Dies bedeutet, dass das Programm den Speicherplatz für die Kommunikationsvariablen selbst verwalten muss. Alternative wäre das gepufferte Senden, was aber mit Unwägbarkeiten und doppeltem Kopieraufwand verbunden ist.
- Schließlich muss man testen ob die Kommunikation stattgefunden hat (d.h. der Auftrag ist bearbeitet):
  - **int** success(**msgid** *m*)
- Danach dürfen die Kommunikationsvariablen modifiziert werden, die Quittung ist ungültig geworden.

Synchoner/Asynchroner Nachrichtenaustausch

- Synchrone und Asynchrone Operationen dürfen gemischt werden. Ist im MPI Standard so implementiert.
- Bisherige Operationen waren *verbindungslos*.
- Alternative sind kanalorientierte Kommunikationsoperationen (oder virtuelle Kanäle):

  - Vor dem erstmaligen senden/empfangen an/von einem Prozess muss mittels **connect** eine Verbindung aufgebaut werden.
  - **send**/**recv** erhalten einen Kanal statt einen Prozess als Adresse.
  - Mehrere Prozesse können auf einen Kanal senden aber nur einer empfangen.
    - **send**(*channel*,$expr_1$,...,$expr_n$)
    - **recv**(*channel*,var_1,...,var_n).
- Wir werden keine kanalorientierten Funktionen verwenden.

Globale Kommunikation

- Ein Prozess will ein *identisches* Datum an alle anderen Prozesse
- *one-to-all broadcast*
- duale Operation ist das Zusammenfassen von individullen Resultaten auf einem Prozeß, z.B. Summenbildung (alle assoziativen Operatoren sind möglich)
- Wir betrachten Austeilen auf verschiedenen Topologien und berechnen Zeitbedarf für store & forward und cut-through routing
- Algorithmen für das Einsammeln ergeben sich durch Umdrehen der Reihenfolge und Richtung der Kommunikationen
- Folgende Fälle werden einzeln betrachtet:
  - Einer-an-alle
  - Alle-an-alle
  - Einer-an-alle mit individuellen Nachrichten
  - Alle-an-alle mit individuellen Nachrichten

Einer-an-alle: Ring

Ein Prozess will ein *identisches* Datum an alle anderen Prozesse versenden:

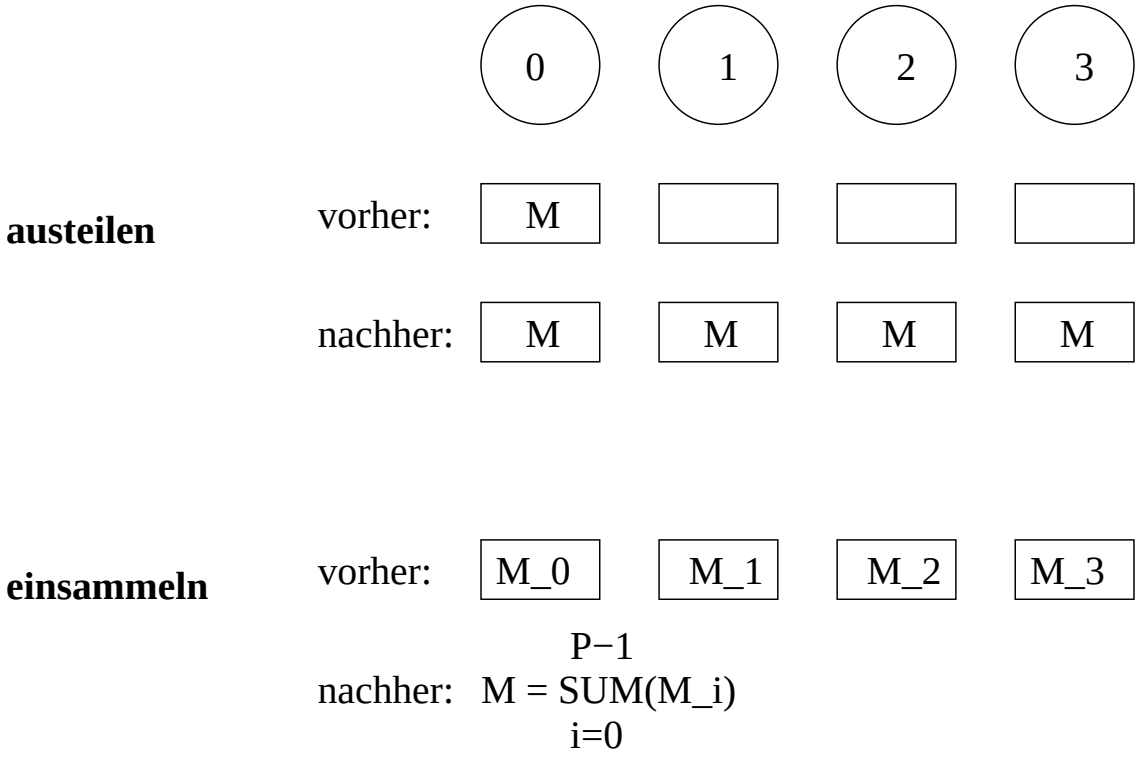

Hier: Kommunikation im Ring mit store & forward:

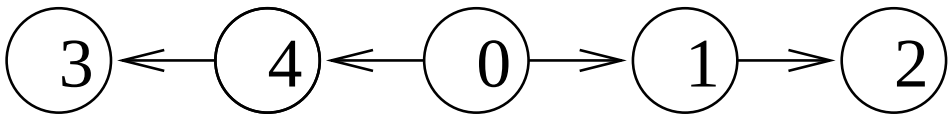

Einer-an-alle: Ring

Programm (Einer-an-alle auf dem Ring)

```
parallel one-to-all-ring
{
    const int P;
    process Π[int p ∈ {0,...,P − 1}]{
        void one_to_all_broadcast(msg *mptr) {
            // Nachrichten empfangen
            if (p > 0  ∧  p ≤ P/2)        recv(Π_{p−1}, *mptr);
            if (p > P/2)                  recv(Π_{(p+1)%P}, *mptr);
            // Nachrichten an Nachfolger weitergeben
            if (p ≤ P/2 − 1)              send(Π_{p+1}, *mptr);
            if (p > P/2 + 1 ∨ p == 0)     send(Π_{(p+P−1)%P}, *mptr);
        }
        ...;
        m=...;
        one_to_all_broadcast(&m);
    }
}
```

Der Zeitbedarf für die Operation beträgt (nearest-neighbor Kommunikation!):

$$T_{one-to-all-ring} = (t_s + t_h + t_w \cdot n) \left\lceil \frac{P}{2} \right\rceil ,$$

wobei $n = |*mptr|$ immer die Länge der Nachricht bezeichne.

Einer-an-alle: Feld

Nun setzen wir eine 2D-Feldstruktur zur Kommunikation voraus. Die Nachrichten laufen folgende Wege:

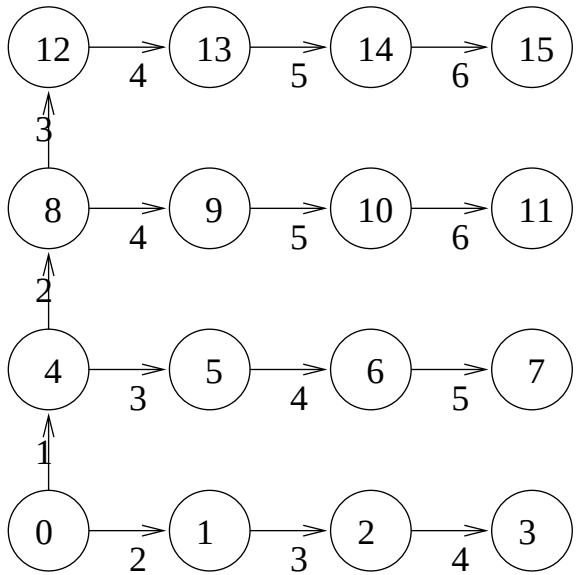

Beachte den zweidimensionalen Prozessindex:

Einer-an-alle: Feld

Programm (Einer an alle auf dem Feld)

```
parallel one-to-all-array
{
    int P, Q;                                   // Feldgröße in x- und y-Richtung
    process Π[int[2] (p,q) ∈ {0,...,P−1} × {0,...,Q−1}] {
        void one_to_all_broadcast(msg *mptr) {
            if (p == 0)
            {                                   // erste Spalte
                if (q > 0)                      recv(Π(p,q−1),*mptr);
                if (q < Q − 1)                  send(Π(p,q+1),*mptr);
            }
            else                        recv(Π(p−1,q),*mptr);
            if (p < P − 1)              send(Π(p+1,q),*mptr);
        }

        msg m=...;
        one_to_all_broadcast(&m);
    }
}
```

Die Ausführungszeit für $P = 0$ beträgt für ein 2D-Feld

$$T_{one-to-all-array2D} = 2(t_s + t_h + t_w \cdot n)(\sqrt{P} - 1)$$

und für ein 3D-Feld

$$T_{one-to-all-array3D} = 3(t_s + t_h + t_w \cdot n)(P^{1/3} - 1).$$

Einer-an-alle: Hypercube

- Wir gehen rekursiv vor. Auf einem Hypercube der Dimension $d = 1$ ist das Problem trivial zu lösen:

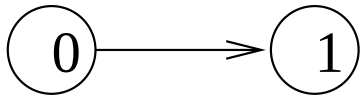

- Auf einem Hypercube der Dimension $d = 2$ schickt 0 erst an 2 und das Problem ist auf 2 Hypercubes der Dimension 1 reduziert:

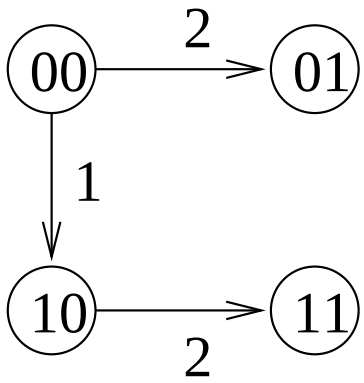

- Allgemein schicken im Schritt $k = 0, \ldots d-1$ die Prozesse

$$\text{je eine Nachricht an } \underbrace{p_{d-1} \ldots p_{d-k}}_{k \text{ Dimens.}} \; 0 \; \underbrace{0 \ldots 0}_{d-k-1 \text{ Dimens.}}$$

$$\underbrace{p_{d-1} \ldots p_{d-k}}_{k \text{ Dimens.}} \; 1 \; \underbrace{0 \ldots 0}_{d-k-1 \text{ Dimens.}}$$

Einer-an-alle: Hypercube

Programm (Einer an alle auf dem Hypercube)

```
parallel one-to-all-hypercube
{
    int d, P = 2^d;
    process Π[int p ∈ {0,...,P − 1}]{
        void one_to_all_broadcast(msg *mptr) {
            int i, mask = 2^d − 1;
            for (i = d − 1; i ≥ 0; i − −){
                mask = mask ⊕ 2^i;
                if (p&mask == 0) {
                    if (p&2^i == 0)                    //die letzten i Bits sind 0
                        send(Π_{p⊕2^i},*mptr);
                    else
                        recv(Π_{p⊕2^i},*mptr);
                }
            }
        }

        msg m = „bla“; one_to_all_broadcast(&m);
    }
}
```

Der Zeitbedarf ist

$$T_{one-to-all-HC} = (t_s + t_h + t_w \cdot n) \operatorname{ld} P$$

Beliebige Quelle $src \in \{0, \ldots, P-1\}$: Ersetze jedes p durch $(p \oplus src)$.

Einer-an-alle: Ring und Feld mit cut-through routing

- Bildet man den Hypercubealgorithmus auf einen Ring ab, erhalten wir folgende Kommunikationsstruktur:

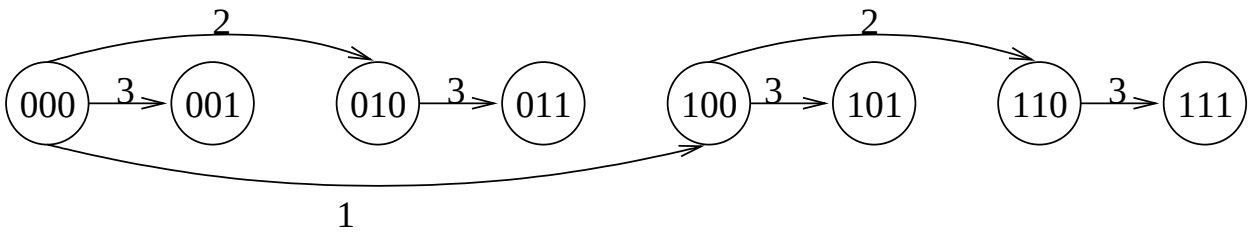

- Es werden keine Leitungen doppelt verwendet, somit erhält man bei cut-through routing:

$$
\begin{aligned}
T_{one-to-all-ring-ct} &= \sum_{i=0}^{\mathrm{ld}\,P\,-1} (t_s + t_w \cdot n + t_h \cdot 2^i) \\
&= (t_s + t_w \cdot n)\,\mathrm{ld}\,P + t_h(P-1)
\end{aligned}
$$

Einer-an-alle: Ring und Feld mit cut-through routing

Bei Verwendung einer Feldstruktur erhält man folgende Kommunikationsstruktur:

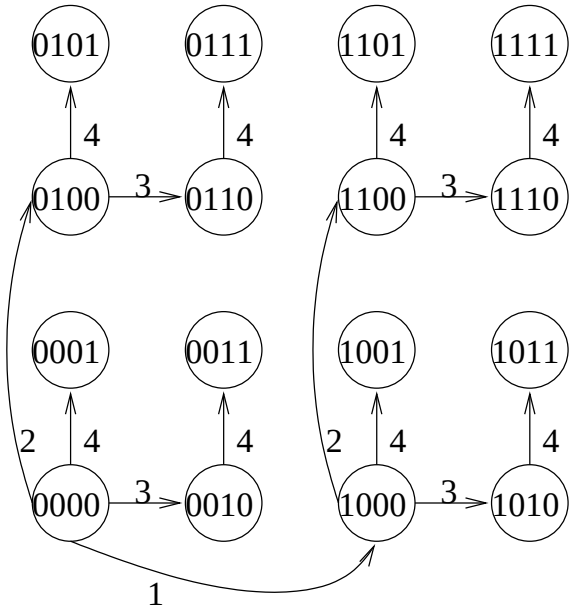

Wieder gibt es keine Leitungskonflikte und wir erhalten:

$$T_{one-to-all-field-ct} = \underbrace{2}_{\substack{\text{jede} \\ \text{Entfernung 2} \\ \text{mal}}} \sum_{i=0}^{\frac{\text{ld}\, P}{2}-1} (t_s + t_w \cdot n + t_h \cdot 2^i)$$

Einer-an-alle: Ring und Feld mit cut-through routing

$$
\begin{aligned}
T_{one-to-all-field-ct} &= (t_s + t_w \cdot n) 2 \frac{\mathrm{ld}\, P}{2} + t_h \cdot 2 \underbrace{\sum_{i=0}^{\frac{\mathrm{ld}\, P}{2}-1} 2^i}_{=\underbrace{2^{\frac{\mathrm{ld}\, P}{2}}}_{=\sqrt{P}} - 1} \\
&= \mathrm{ld}\, P (t_s + t_w \cdot n) + t_h \cdot 2(\sqrt{P} - 1)
\end{aligned}
$$

Insbesondere beim Feld ist der Term mit t_h vernachlässigbar und wir erhalten die Hypercubeperformance auch auf weniger mächtigen Topologien! Selbst für $P = 1024 = 32 \times 32$ fällt t_h nicht ins Gewicht, somit werden dank cut-through routing keine physischen Hypercube-Strukturen mehr benötigt.