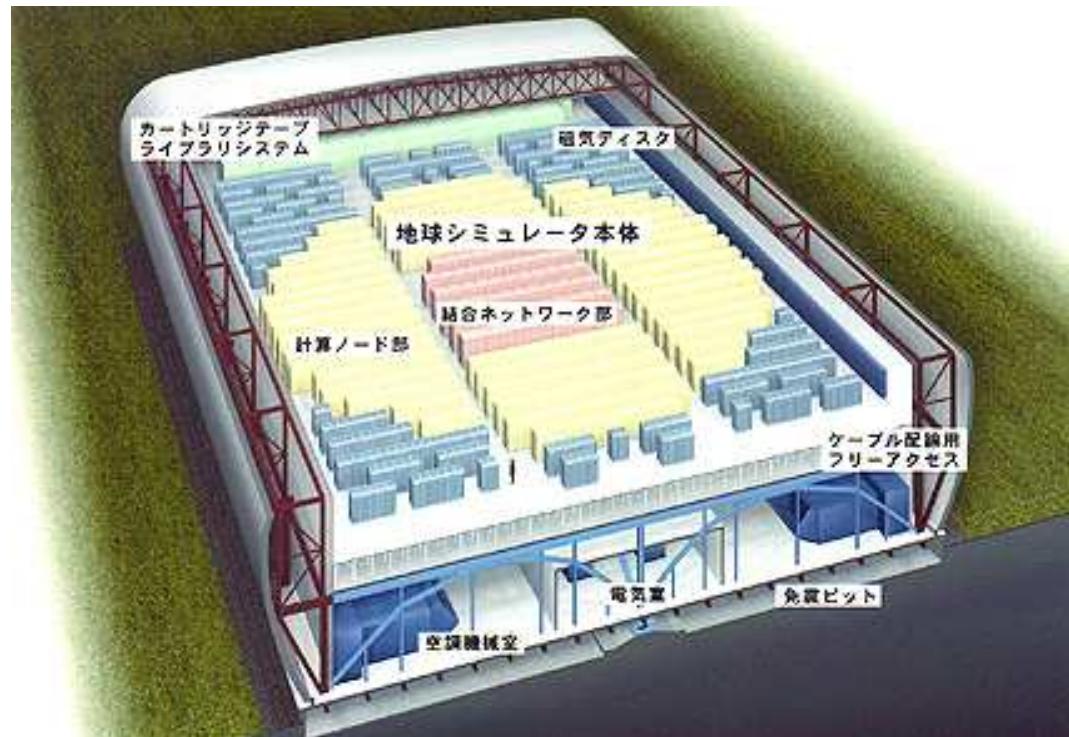
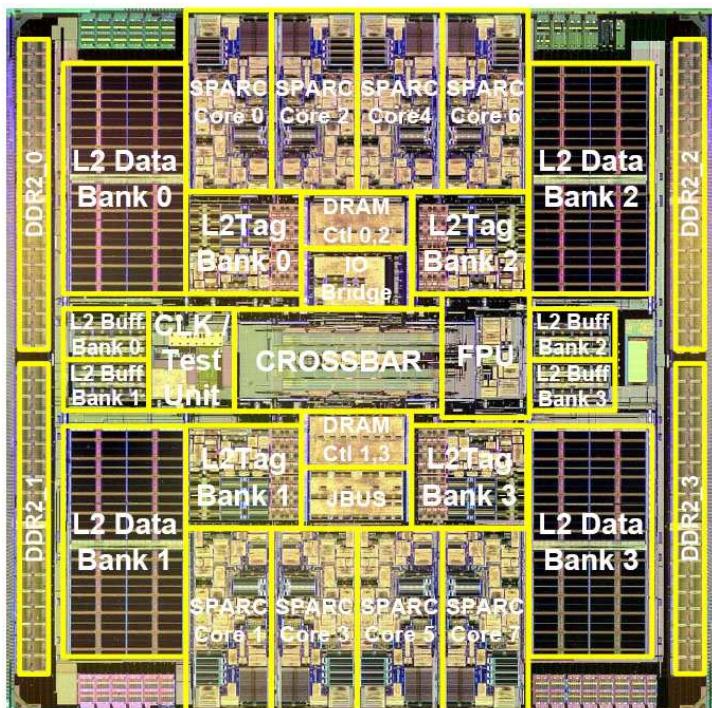


Parallel Algorithmen

Peter Sanders

Institut für Theoretische Informatik —
Algorithmik II



Warum Parallelverarbeitung

Geschwindigkeitsteigerung: p Computer, die gemeinsam an einem Problem arbeiten, lösen es **bis zu** p mal so schnell. Aber, viele Köche verderben den Brei \rightsquigarrow gute Koordinationsalgorithmen

Energieersparnis: Zwei Prozessoren mit halber Taktfrequenz brauchen weniger als eine voll getakteter Prozessor. (Leistung \approx Spannung · Taktfrequenz)

Speicherbeschränkungen von Einzelprozessoren

Kommunikationsersparnis: wenn Daten verteilt anfallen kann man sie auch verteilt (vor)verarbeiten

Thema der Vorlesung

Grundlegende Methoden der parallelen Problemlösung

- Parallelisierung **sequentieller Grundtechniken**: Sortieren, Datenstrukturen, Graphenalgorithmen,...
- Basis**kommunikationsmuster**
- Lastverteilung**
- Betonung von **beweisbaren Leistungsgarantien**
- Aber **Anwendbarkeit** in „Blickweite“

Überblick

- Modelle, Einfache Beispiele
- Matrixmultiplikation
- Broadcasting
- Sortieren
- Allgemeiner Datenaustausch
- Lastverteilung I,II,III
- Umwandlung verkettete Liste → Array
- Hashing, Prioritätslisten
- einfache Graphenalgorithmen
- Graphpartitionierung

Literatur

Skript

[Kumar, Grama, Gupta und Karypis],

Introduction to Parallel Computing. Design and Analysis of Algorithms,

Benjamin/Cummings, 1994. Praktikerbuch

[Leighton], Introduction to Parallel Algorithms and Architectures,

Morgan Kaufmann, 1992.

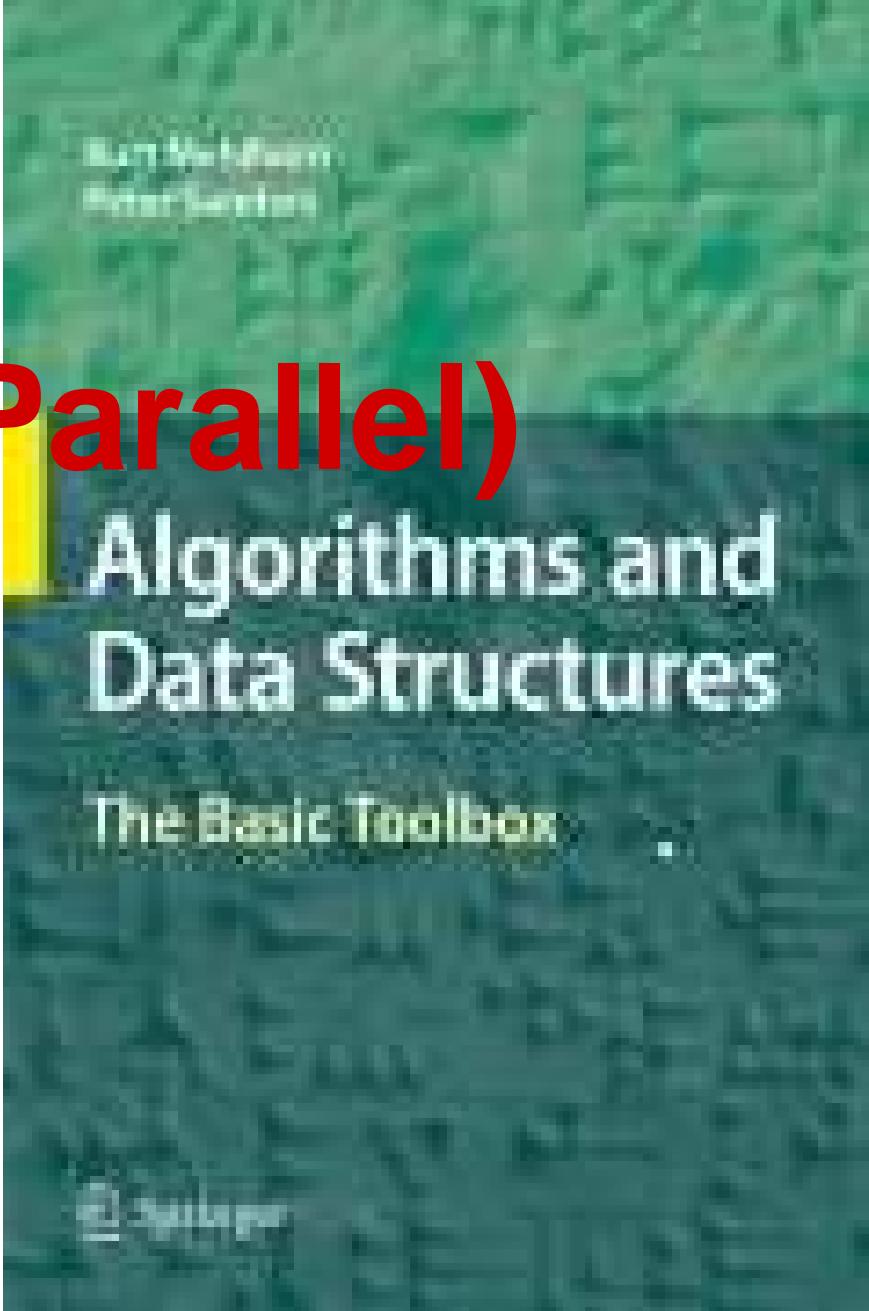
Theoretische Algorithmen auf konkreten Netzwerken

[JáJá], An Introduction to Parallel Algorithms, Addison Wesley, 1992.

PRAM

[Sanders, Worsch],

Parallele Programmierung mit MPI – ein Praktikum, Logos, 1997.



(Parallel)
Algorithms and
Data Structures

The Basic Toolbox

Parallelverarbeitung am ITI Sanders

- Multicore Basisalgorithmen, z.B. g++ STL parallel mode
- Massiv parallele Algorithmen Axtmann
- Basisalgorithmen für Datenbanken (Kooperation SAP)
- Big-Data Frameworks Bingmann
- Lastverteilung Speck, Maier
- (Hyper)Graphpartitionierung (Schulz, Schlag, Akhremtsev)
- Kommunikationseffiziente Algorithmen Hübschle-Schneider, Schlag
- Shared Memory Datenstrukturen Maier, Akhremtsev
- Bildverarbeitung Arz
- Hochenergiephysik Funke

Schwesterveranstaltungen

Parallelprogrammierung: Tichy, Karl, Streit

Modelle der Parallelverarbeitung: viel theoretischer,

Komplexitätstheorie, . . .

Worsch

Algorithmen in Zellularautomaten: spezieller, radikaler, theoretischer

Worsch

Rechnerarchitektur: Karl

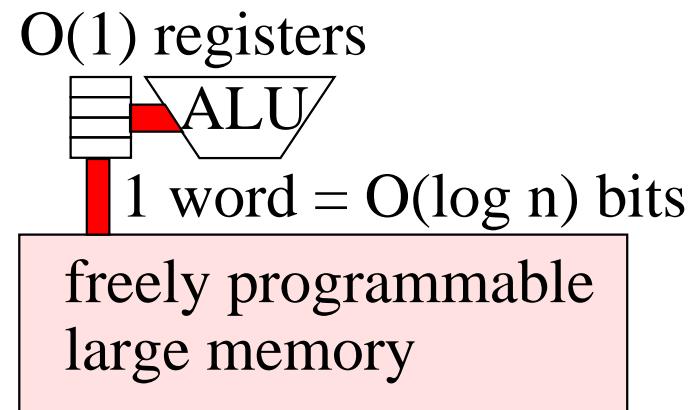
GPUs: Dachsbacher

+ andere Algorithmkvorlesungen

RAM/von Neumann Modell

Analyse: zähle Maschinenbefehle —
load, store, Arithmetik, Branch,...

- Einfach
- Sehr erfolgreich



Algorithmenanalyse:

- Zyklen zählen: $T(I)$, für gegebene Probleminstanz I .

- **Worst case** in Abhängigkeit von Problemgröße:

$$T(n) = \max_{|I|=n} T(I)$$

- **Average case**: $T_{\text{avg}}(n) = \frac{\sum_{|I|=n} T(I)}{|\{I : |I|=n\}|}$ Beispiel: Quicksort hat average case Ausführungszeit $\mathcal{O}(n \log n)$

- Probabilistische (randomisierte) Algorithmen: $T(n)$ (worst case) ist eine **Zufallsvariable**. Wir interessieren uns z.B. für deren Erwartungswert (später mehr).

Nicht mit average case verwechseln.

Beispiel: Quicksort mit zufälliger Pivotwahl hat erwarteten worst case Aufwand $\mathbb{E}[T(n)] = \mathcal{O}(n \log n)$

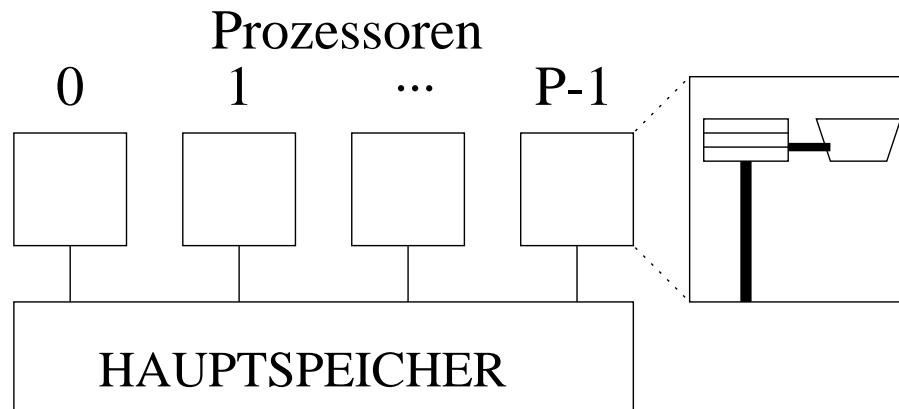
Algorithmenanalyse: Noch mehr Konventionen

- $\mathcal{O}(\cdot)$ plättet lästige Konstanten
- Sekundärziel: Speicherplatz
- Die Ausführungszeit kann von mehreren Parametern abhängen:
Beispiel: Eine effiziente Variante von Dijkstra's Algorithmus für kürzeste Wege benötigt Zeit $\mathcal{O}(m + n \log n)$ wenn n die Anzahl Knoten und m die Anzahl Kanten ist. (Es muss immer klar sein, welche Parameter was bedeuten.)

Ein einfaches paralleles Modell: PRAMs

Idee: RAM so wenig wie möglich verändern.

- p Prozessoren (ProzessorElemente); nummeriert 1.. p (oder 0.. $p - 1$). Jedes PE kennt p .
- Ein Maschinenbefehls pro Takt und Prozessor **synchron**
- Gemeinsamer **globaler** Speicher



Zugriffskonflikte?

EREW: Exclusive Read Exclusive Write. Gleichzeitige Zugriffe verboten

CREW: Concurrent Read Exclusive Write. Gleichzeitiges lesen OK.

Beispiel: Einer schreibt, andere lesen = „Broadcast“

CRCW: Concurrent Read Concurrent Write. Chaos droht:

common: Alle Schreiber müssen sich einig sein. Beispiel: OR in konstanter Zeit (AND?)



arbitrary: Irgendeiner setzt sich durch



priority: Schreiber mit kleinster Nummer setzt sich durch

combine: Alle Werte werden kombiniert. Zum Beispiel Summe.

Beispiel: Global Or

Eingabe in $x[1..p]$

Sei Speicherstelle **Result**= 0

Parallel auf Prozessor $i = 1..p$

```
if x[i] then Result := 1
```

Global And

Sei Speicherstelle **Result**= 1

```
if not x[i] then Result := 0
```

Beispiel: Maximum auf common CRCW PRAM

[JáJá Algorithmus 2.8]

Input: $A[1..n]$ // distinct elements

Output: $M[1..n]$ // $M[i] = 1$ iff $A[i] = \max_j A[j]$

forall $(i, j) \in \{1..n\}^2$ **dopar** $B[i, j] := A[i] \geq A[j]$

forall $i \in \{1..n\}$ **dopar**

$M[i] := \bigwedge_{j=1}^n B[i, j]$ // parallel subroutine

$\mathcal{O}(1)$ Zeit

$\Theta(n^2)$ Prozessoren (!)

i	A	B	1	2	3	4	5	<-	j	M
1	3		*	0	1	0	1			1
2	5		1	*	1	0	1			1
3	2		0	0	*	0	1			1
4	8		1	1	1	*	1			1
5	1		0	0	0	0	*			1
	A		3	5	2	8	1			

i	A	B	1	2	3	4	5	<-	j	M
1	3		*	0	1	0	1			0
2	5		1	*	1	0	1			0
3	2		0	0	*	0	1			0
4	8		1	1	1	*	1			1->maxValue=8
5	1		0	0	0	0	*			0

Formulierung paralleler Algorithmen

- Pascal-ähnlicher Pseudocode
- Explizit parallele Schleifen [JáJá S. 72]
- Single Program Multiple Data Prinzip. Der Prozessorindex wird genutzt um die Symmetrie zu brechen. \neq SIMD !

Synchron versus asynchron

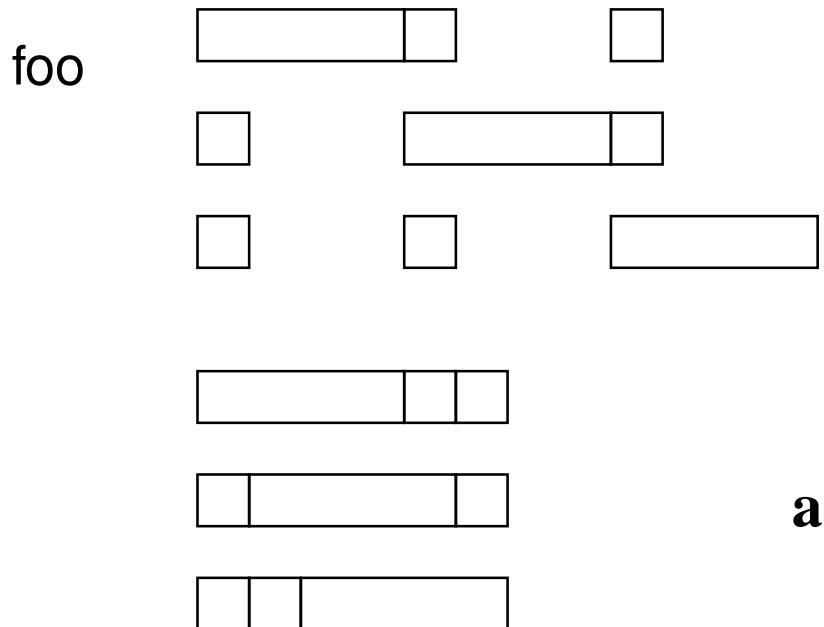
PE index is j

for $i = 1$ **to** p **do** (a)synchronously

if $i = j$ **then**

for $k = 1$ **to** l **do** foo

else



pl foos versus $p + l - 1$ foos.

Analyse paralleler Algorithmen

Im Prinzip nur ein zusätzlicher Parameter: p .

Finde Ausführungszeit $T(I, p)$.

Problem: Interpretation.

Work: $W = pT(p)$ ist ein Kostenmaß. (z.B. Max: $W = \Theta(n^2)$)

(absoluter) Speedup: $S = T_{\text{seq}}/T(p)$ Beschleunigung. Benutze besten bekannten sequentiellen Algorithmus. Relative Beschleunigung

$S_{\text{rel}} = T(1)/T(p)$ ist i.allg. was anderes!

(z.B. Maximum: $S = \Theta(n)$, $S_{\text{rel}} = \Theta(n^2)$)

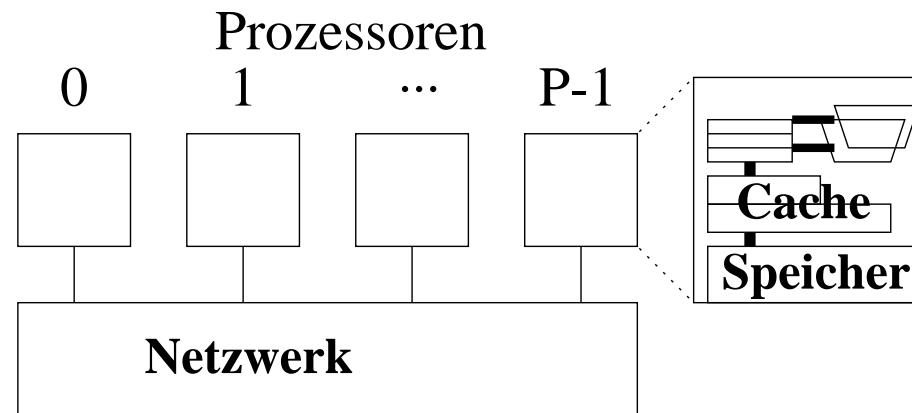
Effizienz: $E = S/p$. Ziel: $E \approx 1$ oder wenigstens $E = \Theta(1)$.

(Sinnvolles Kostenmaß?) „Superlineare Beschleunigung“: $E > 1$.

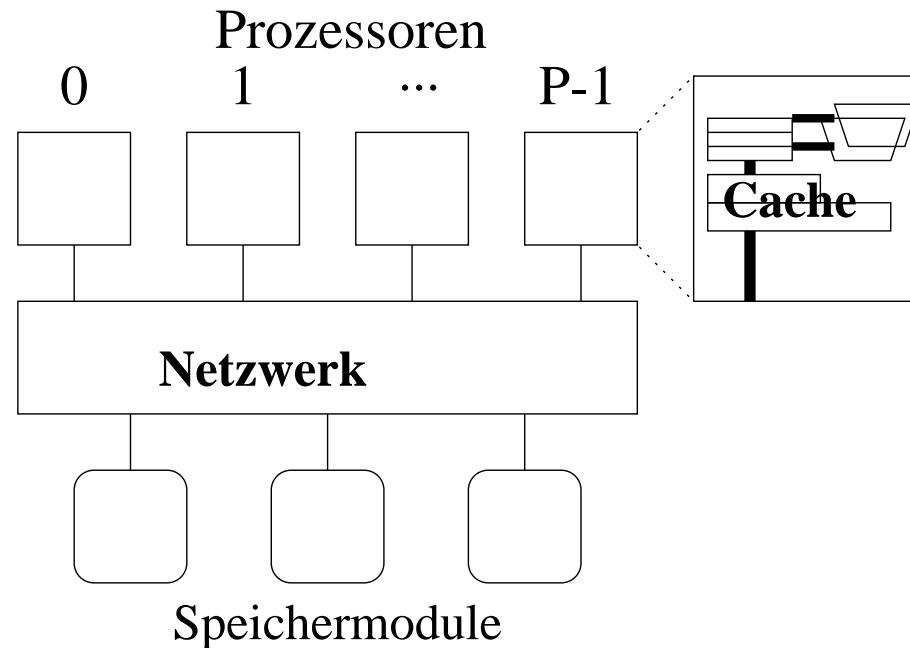
(möglich?). Beispiel Maximum: $E = \Theta(1/n)$.

PRAM vs. reale Parallelrechner

Distributed Memory



(Symmetric) Shared Memory



Probleme

- **Asynchron** \rightsquigarrow Entwurf, Analyse, Implementierung, Debugging
viele schwieriger als PRAM
- **Contention** (Stau) für gleiche Speichermodule. Beispiel: Der $\Theta(1)$ PRAM Algorithmus für globales OR wird zu $\Theta(p)$.
- **Lokaler/Cache-Speicher** ist (viel) schneller zugreifbar als **globaler Speicher**
- Das **Netzwerk** wird mit zunehmendem p **komplizierter** und die Verzögerungen werden größer.
- Contention im Netzwerk
- Es interessiert der **maximale lokale Speicherverbrauch** und weniger die Summe der lokalen Speicherverbräuche

Realistische Shared Memory Modelle

- asynchron
- CRQW: concurrent read **queued write**. Wenn x PEs gleichzeitig auf eine Speicherstelle zugreifen kostet das Zeit $\mathcal{O}(x)$.
- konsistente Schreiboperationen mit Hilfe **atomarer Instruktionen**
- Speicherhierarchien

Atomare Instruktionen: Compare-And-Swap

Allgemein und weit verbreitet:

Function CAS(a , expected, desired) : {0, 1}

BeginTransaction

if $*a = \text{expected}$ **then**

else

$*a := \text{desired}$; **return** 1// success

$\text{expected} := *a$; **return** 0// failure

EndTransaction

Weitere Operationen für konsistenten Speicherzugriff:

- Fetch-and-add
- Hardwaretransaktionen

Function `fetchAndAdd(a, Δ)`

expected:= $*a$

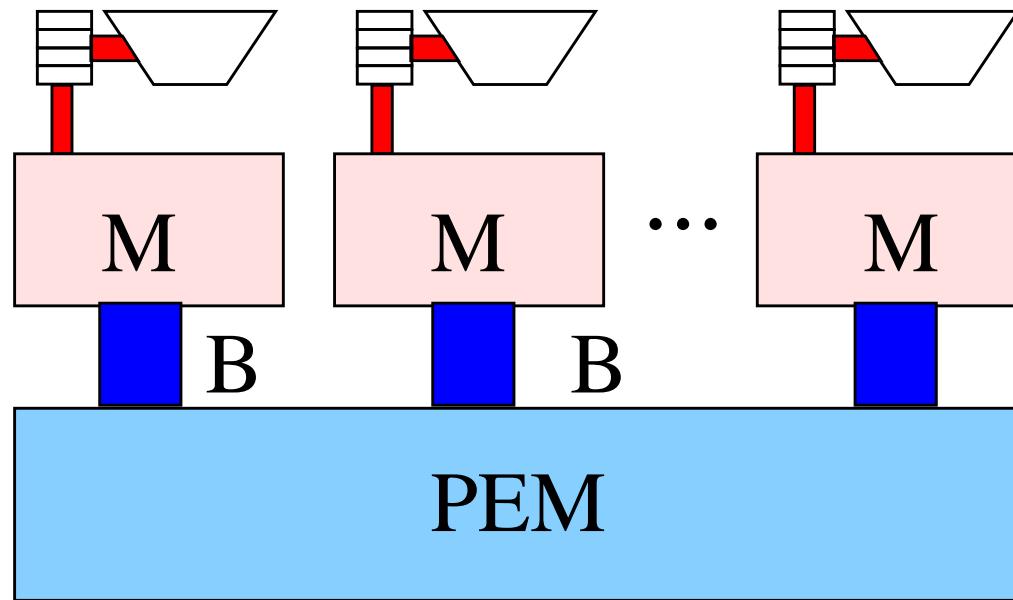
repeat

 desired:= expected + Δ

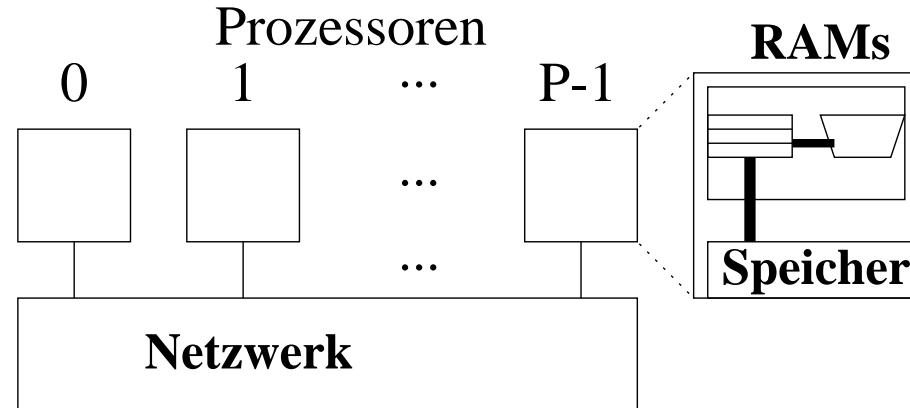
until `CAS(a , expected, desired)`

return desired

Parallel External Memory



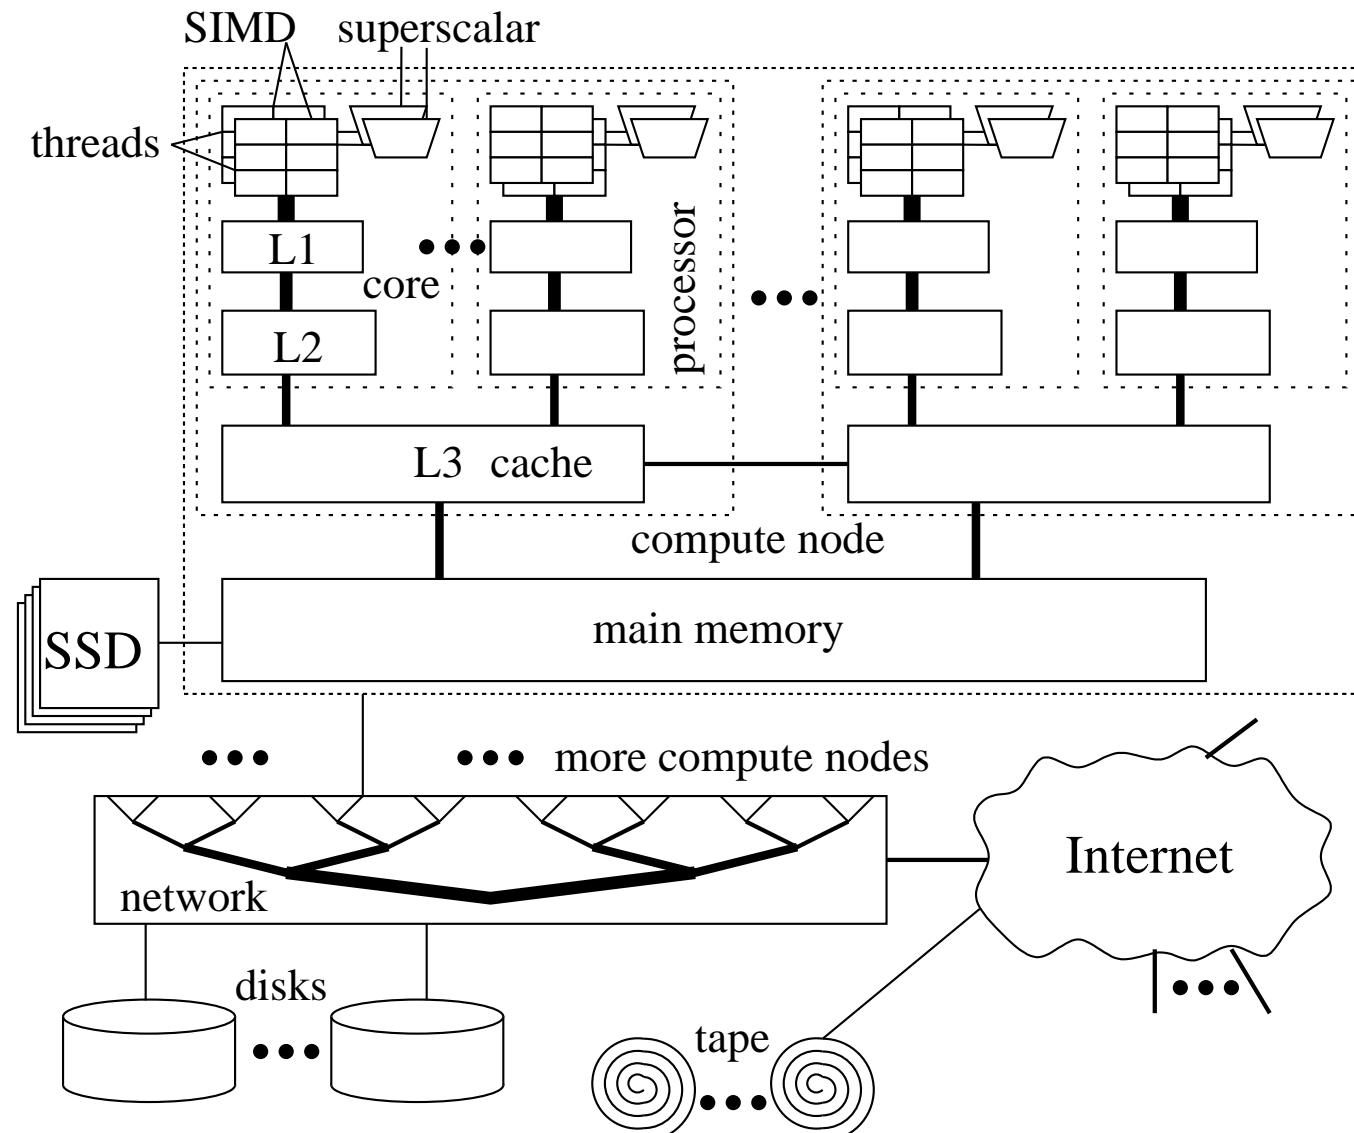
Modelle mit Verbindungsnetzwerken



- Prozessoren sind RAMs
- asynchrone** Programmabarbeitung
- Interaktion durch **Nachrichtenaustausch**

Entscheidend ist das Kostenmodell für den Nachrichtenaustausch

Reale Maschinen Heute



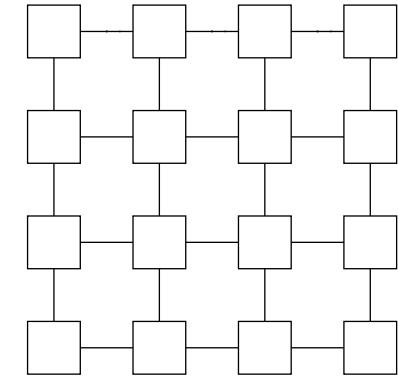
Umgang mit komplexen Hierarchien

These: mit **flachen** Modellen, vor allem bei **verteiltem Speicher**
kommen wir sehr weit.

- Entwerfe verteilt, implementiere hierarchieangepaßt
- Shared-Memory Unterprogramme auf Knoten

Explizites „Store-and-Forward“

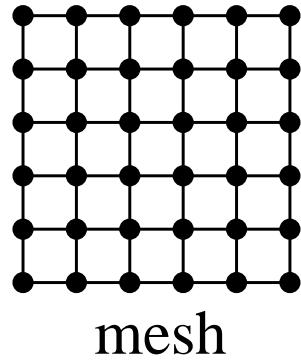
- Wir kennen die Struktur des Verbindungsgraphen $(V = \{1, \dots, p\}, E \subseteq V \times V)$. Varianten:
 - $V = \{1, \dots, p\} \cup R$ mit zusätzlichen „dummen“ Routerknoten (ggf. mit Pufferspeicher).
 - Busse → Hyperedges
- Zu jeder Zeiteinheit kann jede Kante maximal k' Datenpakete konstanter Länge transportieren (meist $k' = 1$)
- In einer k -Port-Maschine kann jeder Knoten k Pakete gleichzeitig senden oder empfangen. $k = 1$ nennt sich **single-ported**.



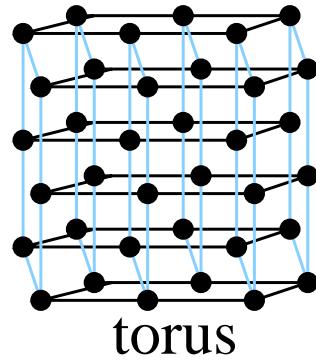
Diskussion

- + einfach formuliert
- low level ⇒ „messy algorithms“
- **Hardwarerouter** erlauben schnelle Komm. wann immer ein Kommunikationspfad gefunden wird.

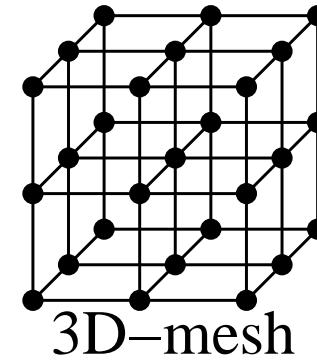
Typische Verbindungsnetzwerke



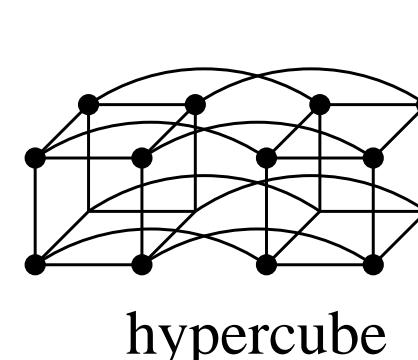
mesh



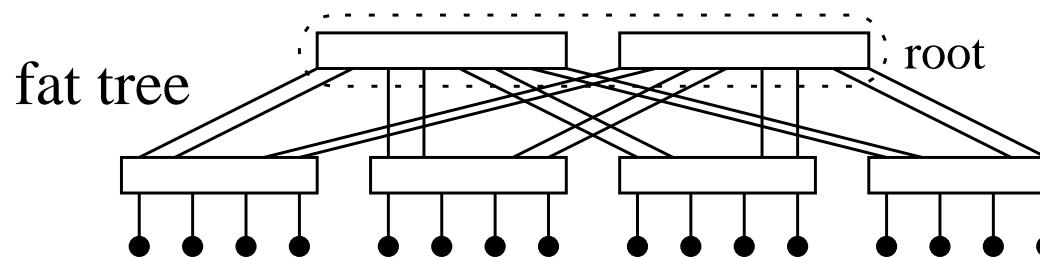
torus



3D-mesh



hypercube



fat tree

root

Vollständige Verknüpfung

- $E = V \times V$, single ported
- $T_{\text{comm}}(m) = T_{\text{start}} + mT_{\text{byte}}$.
- + Realistische Behandlung von Nachrichtenlängen
- + Viele Verbindungsnetze approximieren vollständige Verknüpfung
⇒ sinnvolle Abstraktion
- + Keine überlasteten Kanten → OK für Hardwarerouter
- + „künstliches“ Vergrößern v. T_{start} , T_{byte}
→ OK für „schwächliche“ Netzwerke
- + Asynchrones Modell
- Etwas Händewedeln bei realen Netzwerken

Vollständige Verknüpfung: Varianten

Was tut PE i in Zeit $T_{\text{comm}}(m) = T_{\text{start}} + mT_{\text{byte}}$?

Nachrichtenlänge m .

halbduplex: 1×senden oder 1×empfangen (auch simplex)

Telefon: 1×senden an PE j und 1×empfangen von PE j

(voll)duplex: 1×senden und 1×empfangen.

Beliebige Kommunikationspartner

Auswirkung auf Laufzeit:

$$T^{\text{duplex}} \leq T^{\text{Telefon}} \leq T^{\text{duplex}/2} \leq 3T^{\text{duplex}}$$

BSP

Bulk Synchronous Parallel

[McColl LNCS Band 1000, S. 46]

Maschine wird durch drei Parameter beschrieben:

p , l und g .

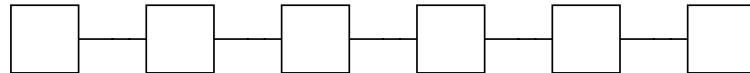
l : Startup overhead für einen **kollektiven** Nachrichtenaustausch – an dem alle PEs beteiligt sind

g : $gap \approx \frac{\text{Rechengeschwindigkeit}}{\text{Kommunikationsbandbreite}}$

Formaler: Eine **h -Relation** ist eine kollektiver Nachrichtenaustausch, bei dem jedes PE bis zu h Pakete sendet oder empfängt (beliebige Adressaten). Der Zeitaufwand ist

$$l + hg .$$

Diskussion



- g und l können eine Funktion von p sein, wenn man eine ganze Klasse von Verbindungsnetzwerken beschreibt (z.B. lineare Gitter).
- + Abstrakt und einfach
- + An viele Architekturen anpassbar
- Nur global synchronisierte Kommunikation
- Nachrichtenlängen nicht berücksichtigt $\rightarrow BSP^*$
- Einfache und schwierige Kommunikationsmuster nicht unterscheidbar. (z.B. Nachbarschaftskommunikation)
- Kosten für einen Kommunikationsschritt auf realer Hardware sind **unklar!**

Erweiterte BSP Modelle

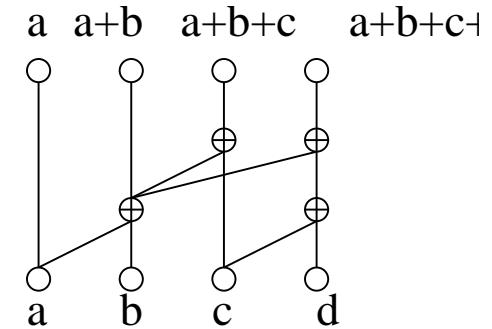
h -Relationen sind nur eines von vielen gutuntersuchten Kommunikationsmustern. Wir können zusätzliche Parameter für **weitere architekturunabhängige Operationen** einführen: (mehr dazu später)

- Broadcast (einer an alle), Minimum, Maximum, Summe, ...
- Nachbarschaftskommunikation auf **logischen Gittern** (oder anderen Graphen)
- ...

Graph- und Schaltkreisdarstellung v. Algorithmen

Viele Berechnungen können als
gerichteter azyklischer Graph dargestellt werden

- Eingabeknoten** haben Eingangsgrad 0
und eine feste Ausgabe
- Ausgabeknoten** haben Ausgangsgrad 0
und Eingangsgrad 1
- Der **Eingangsgrad** ist durch
eine kleine Konstante beschränkt.
- Innere Knoten berechnen eine **Funktion**, die sich in konstanter Zeit
berechnen lässt.



Schaltkreise

- Variante: Wenn statt Maschineworten, konstant viele bits verarbeitet werden spricht man von **Schaltkreisen**.
- Die **Tiefe $d(S)$** des Berechnungs-DAG ist die Anzahl innerer Knoten auf dem längsten Pfad von einem Eingang zu einem Ausgang. Tiefe~Rechenzeit
- Wenn man für jede Eingabegröße (algorithmisch) einen Schaltkreis angibt, spricht man von **Schaltkreisfamilien**

Zusammenhang mit PRAMs

DAG→PRAM

Idee: Ordne den DAG S in $d(S)$ Schichten an. Berechne Operationen auf Schicht i in Phase i .

- Die Struktur muß „hinreichend einfach“ sein → Theorie **uniformer Schaltkreisfamilien** (nicht hier [z.B. Vollmar, Worsch; Modelle der Parallelverarbeitung; Teubner 1995])

PRAM→DAG

- Schleifen ausrollen
- if then else** darf nicht von Eingabe abhängen (**oblivious computation**).

DAG → Verbindungsnetzwerke

Wir müssen den DAG in das Netzwerk **einbetten**:

- Berechnungsknoten → Prozessoren
- DAG-Kanten → **Pfade** in Verbindungsnetzwerk
- Ausführungszeit ist Funktion der Knotenlasten, Kantenlasten und Pfadlängen in jeder einzelnen Schicht des DAG.
- Hardwarerouter: Pfadlängen sind egal.

Beispiel: Assoziative Operationen (=Reduktion)

Satz 1. Sei \oplus ein assoziativer Operator, der in konstanter Zeit berechnet werden kann. Dann lässt sich

$$\bigoplus_{i < n} x_i := ((x_0 \oplus x_1) \oplus x_2) \oplus \dots \oplus x_{n-1}$$

in Zeit $\mathcal{O}(\log n)$ auf einer PRAM berechnen und in Zeit $\mathcal{O}(T_{\text{start}} \log n)$ auf einem linearen Array mit Hardwarerouter

Beispiele: $+$, \cdot , \max , \min , ... (z.B. ? nichkommutativ?)

Beweisskizze für $n = 2^k$ (oBdA?)

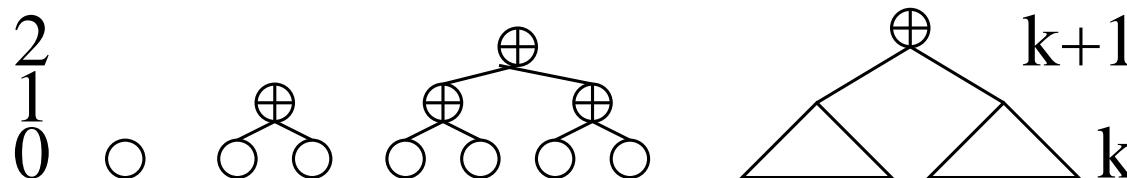
Induktionsannahme: \exists Schaltkreis d. Tiefe k für $\bigoplus_{i < 2^k} x_i$

$k = 0$: trivial

$k \rightsquigarrow k + 1$:

$$\bigoplus_{i < 2^{k+1}} x_i = \underbrace{\bigoplus_{i < 2^k} x_i}_{\text{Tiefe } k+1} \oplus \underbrace{\bigoplus_{i < 2^k} x_{i+2^k}}_{\text{Tiefe } k \text{ (IA)}}$$

■



PRAM Code

PE index $i \in \{0, \dots, n - 1\}$

active := 1

for $0 \leq k < \lceil \log n \rceil$ **do**

if active **then**

if bit k of i **then**

 active := 0

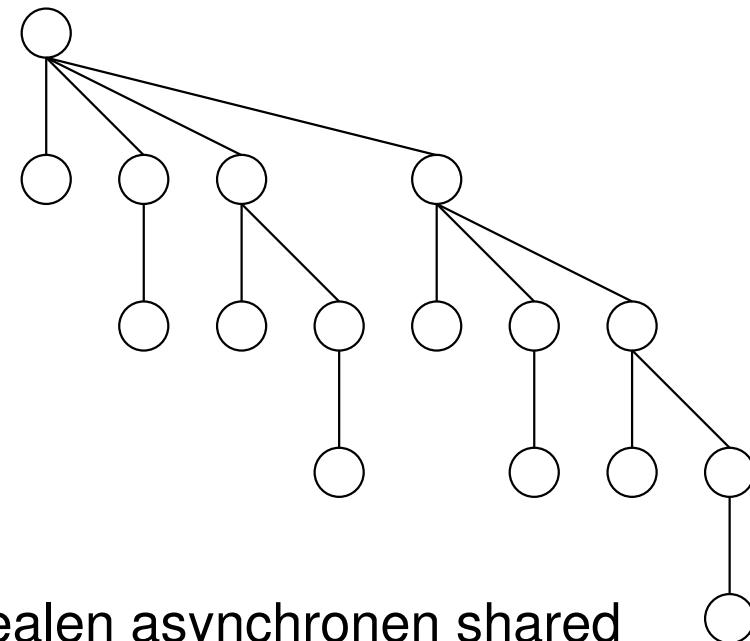
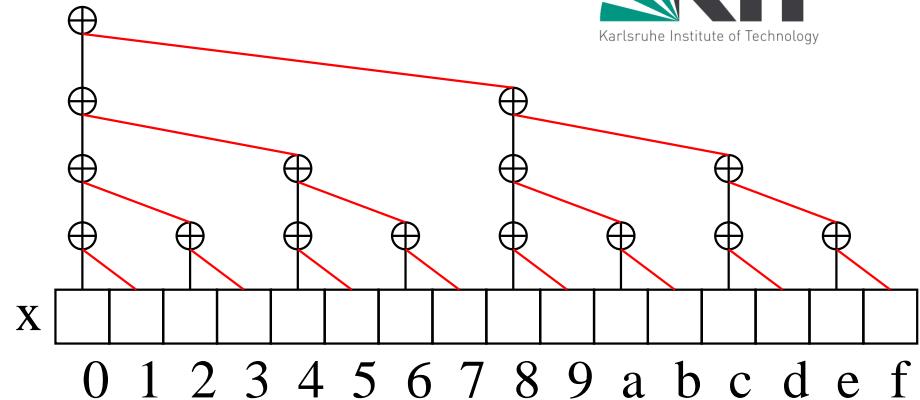
else if $i + 2^k < n$ **then**

$x_i := x_i \oplus x_{i+2^k}$

//result is in x_0

Vorsicht: Viel komplizierter auf einer realen asynchronen shared memory Maschine.

Speedup? Effizienz?



$\log x$ bei uns immer $\log_2 x$

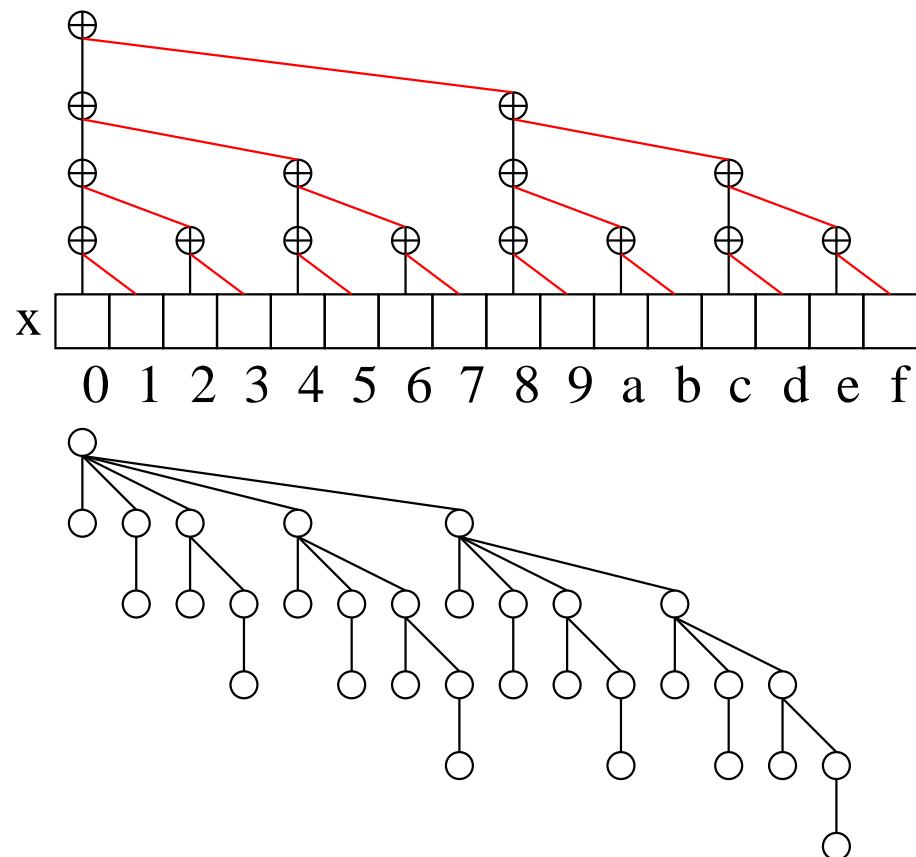
Analyse

n PEs

Zeit $\mathcal{O}(\log n)$

Speedup $\mathcal{O}(n/\log n)$

Effizienz $\mathcal{O}(1/\log n)$



Weniger ist Mehr

p PEs

Jedes PE addiert

n/p Elemente sequentiell

Dann parallele Summe

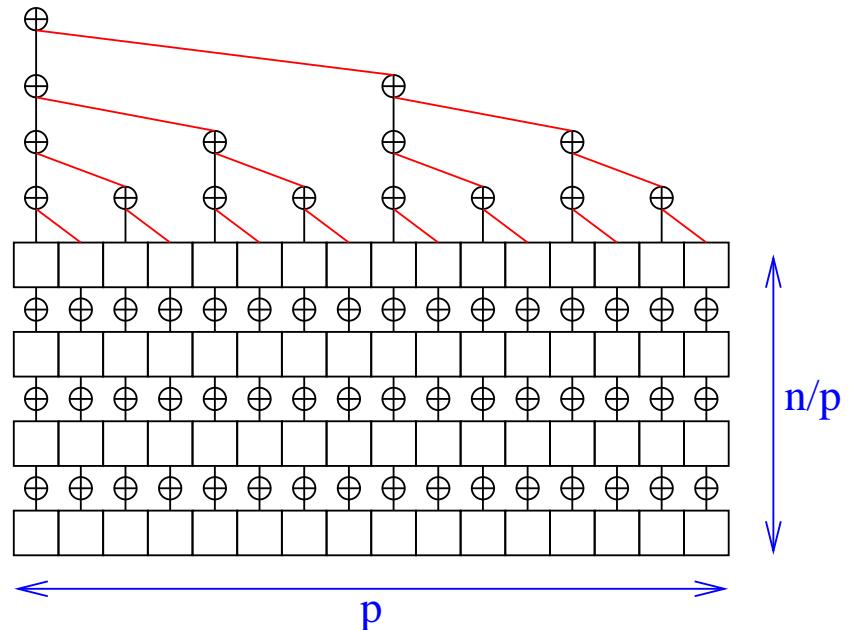
für p Teilsummen

Zeit $T_{\text{seq}}(n/p) + \Theta(\log p)$

Effizienz

$$\frac{T_{\text{seq}}(n)}{p(T_{\text{seq}}(n/p) + \Theta(\log p))} = \frac{1}{1 + \Theta(p \log(p))/n} = 1 - \Theta\left(\frac{p \log p}{n}\right)$$

falls $n \gg p \log p$



Distributed Memory Machine

PE index $i \in \{0, \dots, n - 1\}$

//Input x_i located on PE i

active := 1

$s := x_i$

for $0 \leq k < \lceil \log n \rceil$ **do**

if active **then**

if bit k of i **then**

 sync-send s to PE $i - 2^k$

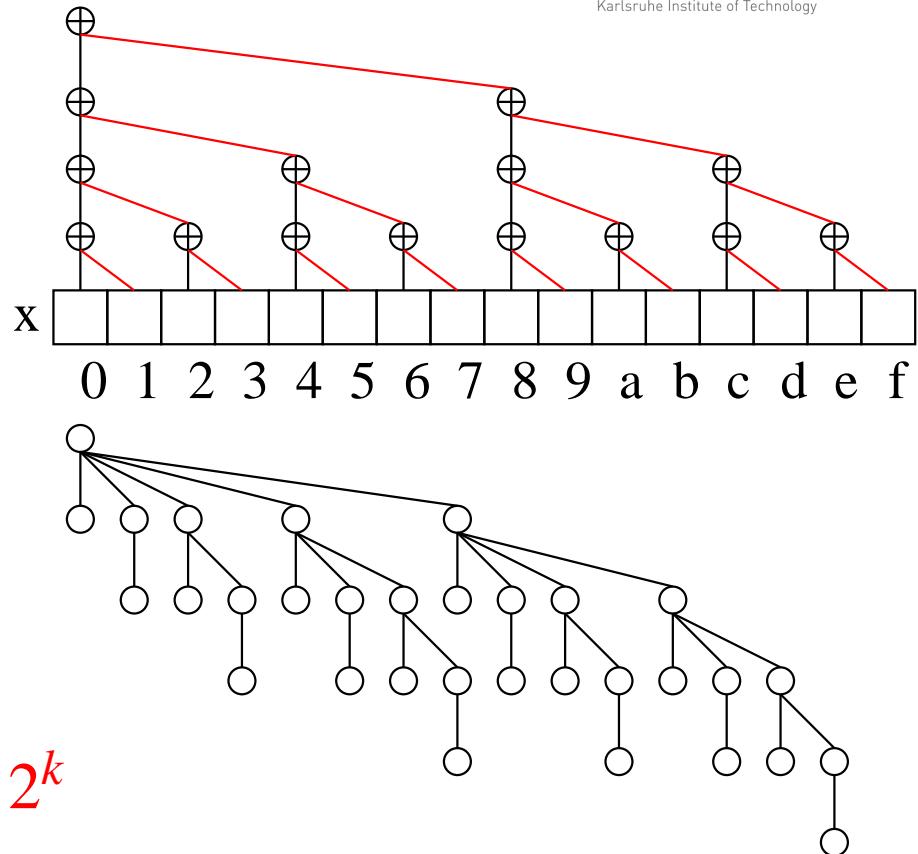
 active := 0

else if $i + 2^k < n$ **then**

 receive s' from PE $i + 2^k$

$s := s \oplus s'$

//result is in s on PE 0



Analyse

vollständige Verknüpfung: $\Theta((T_{\text{start}} + T_{\text{byte}}) \log p)$

lineares Array: $\Theta(p)$: Schritt k braucht Zeit 2^k .

lineares Array mit Router: $\Theta((T_{\text{start}} + T_{\text{byte}}) \log p)$, weil edge congestion (Kantenlast) in jedem Schritt eins ist.

BSP $\Theta((l + g) \log p) = \Omega(\log^2 p)$

Beliebiges $n > p$: jeweils zusätzliche Zeit $T_{\text{seq}}(n/p)$

Diskussion Reduktionsoperation

- Binärbaum führt zu logarithmischer Ausführungszeit
- Nützlich auf den meisten Modellen
- Brent's Prinzip: Ineffiziente Algorithmen werden durch Verringerung der Prozessorzahl effizient
- Später: Reduktion komplexer Objekte. Zum Beispiel Vektoren, Matrizen

Matrixmultiplikation

Gegeben: Matrizen $A \in \mathbf{R}^{n \times n}$, $B \in \mathbf{R}^{n \times n}$

mit $\textcolor{violet}{A} = ((a_{ij}))$ und $\textcolor{violet}{B} = ((b_{ij}))$

R: Halbring

$\textcolor{violet}{C} = ((c_{ij})) = A \cdot B$ bekanntlich gemäß:

$$\textcolor{violet}{c}_{ij} = \sum_{k=1}^{\textcolor{violet}{n}} a_{ik} \cdot b_{kj}$$

Arbeit: $\Theta(n^3)$ arithmetische Operationen

(bessere Algorithmen falls in R Subtraktion möglich)

Ein erster PRAM Algorithmus

n^3 PEs

for $i := 1$ **to** n **dopar**

for $j := 1$ **to** n **dopar**

$$c_{ij} := \sum_{k=1}^n a_{ik} \cdot b_{kj} \quad // n \text{ PE parallel sum}$$

Ein PE für jedes Teilprodukt $c_{ikj} := a_{ik} b_{kj}$

Zeit $\mathcal{O}(\log n)$

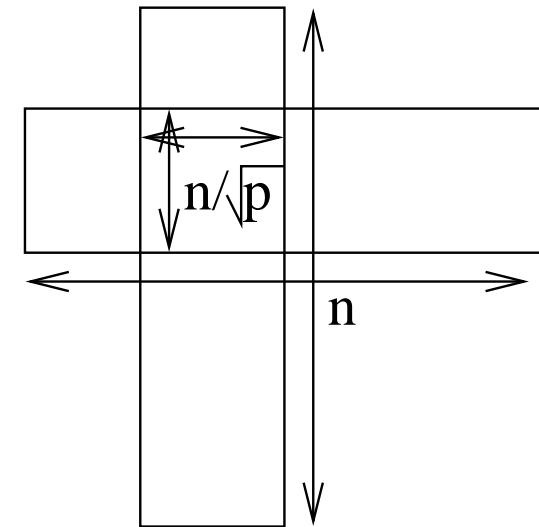
Effizienz $\mathcal{O}(1/\log n)$

Verteilte Implementierung I

$p \leq n^2$ PEs

```
for i:= 1 to n dopar
    for j:= 1 to n dopar
         $c_{ij} := \sum_{k=1}^n a_{ik} \cdot b_{kj}$ 
```

Teile jedem PE n^2/p der c_{ij} zu



- Begrenzte Skalierbarkeit
- Hohes Kommunikationsvolumen. Zeit $\Omega\left(T_{\text{byte}} \frac{n^2}{\sqrt{p}}\right)$

Verteilte Implementierung II-1

[Dekel Nassimi Sahni 81, KGGK Section 5.4.4]

Sei $p = N^3$, n ein Vielfaches von N

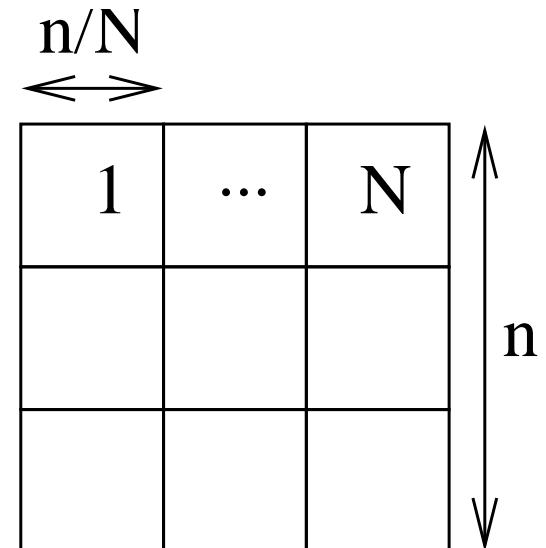
Fasse A, B, C als $N \times N$ Matrizen auf,
jedes Element ist $n/N \times n/N$ Matrix

for $i := 1$ to N **dopar**

for $j := 1$ to N **dopar**

$$c_{ij} := \sum_{k=1}^N a_{ik} b_{kj}$$

Ein PE für jedes Teilprodukt $c_{ikj} := a_{ik} b_{kj}$



Verteilte Implementierung II-2

store a_{ik} in PE $(i, k, 1)$

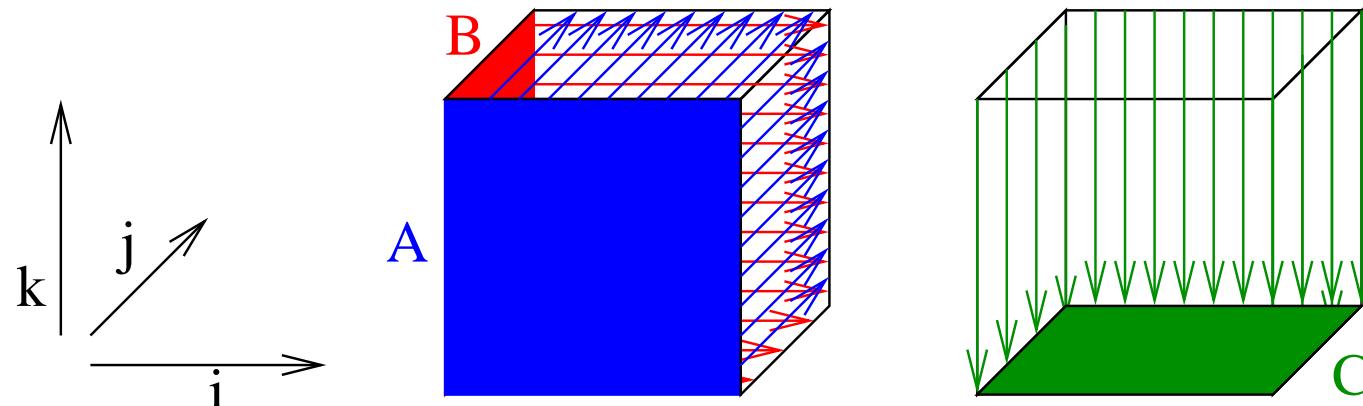
store b_{kj} in PE $(1, k, j)$

PE $(i, k, 1)$ broadcasts a_{ik} to PEs (i, k, j) for $j \in \{1..N\}$

PE $(1, k, j)$ broadcasts b_{kj} to PEs (i, k, j) for $i \in \{1..N\}$

compute $c_{ikj} := a_{ik} b_{kj}$ on PE (i, k, j) // local!

PES (i, k, j) for $k \in \{1..N\}$ compute $c_{ij} := \sum_{k=1}^N c_{ikj}$ to PE $(i, 1, j)$



Analyse, Fully Connected u.v.a.m.

store a_{ik} in PE $(i, k, 1)$ // free (or cheap)

store b_{kj} in PE $(1, k, j)$ // free (or cheap)

PE $(i, k, 1)$ broadcasts a_{ik} to PEs (i, k, j) for $j \in \{1..N\}$

PE $(1, k, j)$ broadcasts b_{kj} to PEs (i, k, j) for $i \in \{1..N\}$

compute $c_{ikj} := a_{ik} b_{kj}$ on PE (i, k, j) // $T_{\text{seq}}(n/N) = \mathcal{O}\left((n/N)^3\right)$

PEs (i, k, j) for $k \in \{1..N\}$ compute $c_{ij} := \sum_{k=1}^N c_{ikj}$ to PE $(i, 1, j)$

Kommunikation:

$$2T_{\text{broadcast}}\left(\overbrace{(n/N)^2}^{\text{Obj. size}}, \overbrace{N}^{\text{PEs}}\right) + T_{\text{reduce}}\left((n/N)^2, N\right) \approx 3T_{\text{broadcast}}\left((n/N)^2, N\right)$$

$$\underset{N \rightsquigarrow p^{1/3}}{\dots} \mathcal{O}\left(\frac{n^3}{p} + T_{\text{byte}} \frac{n^2}{p^{2/3}} + T_{\text{start}} \log p\right)$$

Diskussion Matrixmultiplikation

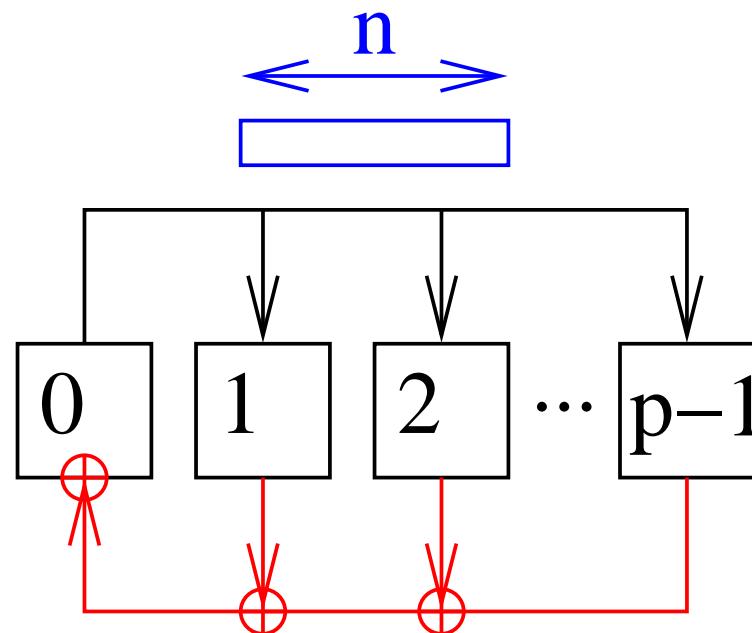
- PRAM Alg. ist guter Ausgangspunkt
- DNS Algorithmus spart Kommunikation braucht aber Faktor $\Theta(\sqrt[3]{p})$ mehr Platz als andere Algorithmen
 - ~~ gut für kleine Matrizen (bei grossen ist Kommunikation eh egal)
- Pattern für vollbesetzte lineare Algebra:
 - Lokale Ops auf Teilmatrizen + Broadcast + Reduce
 - z.B. Matrix-Vektor-Produkt, LGS lösen,...

Beispiel $T_{\text{byte}} = 2^{-29} \text{s}$, $T_{\text{start}} = 2^{-17} \text{s}$, $p = 2^{12}$, $n = 2^{12}$,
8GFLOPS/PE

Broadcast (Rundruf?) und Reduktion

Broadcast: Einer für alle

Ein PE (z.B. 0) schickt Nachricht der Länge n an alle



Reduktion: Alle für einen

Ein PE (z.B. 0) empfängt **Summe** v. p Nachrichten der Länge n
(Vektoraddition \neq lokale Addition!)

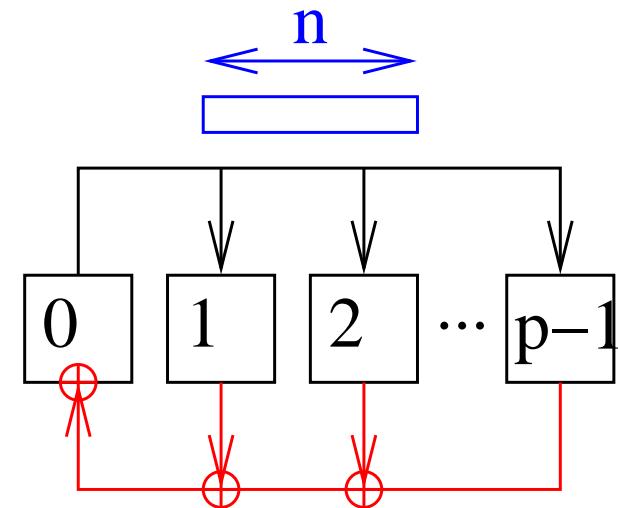
Broadcast \rightsquigarrow Reduktion

Kommunikationsrichtung **umdrehen**

Korrespondierende Teile
ankommender und eigener
Nachrichten **addieren**

Alle folgenden
Broadcastalgorithmen ergeben
Reduktionsalgorithmen
für **kommutative und assoziative Operationen**.

Die meisten (ausser Johnsson/Ho und speziellen Einbettungen)
funktionieren auch bei nichtkommutativen Operationen.



Modellannahmen

- fully connected
- vollduplex – paralleles Senden und Empfangen

Varianten: halbduplex also senden oder empfangen, BSP, Einbettung in konkrete Netzwerke

Naiver Broadcast [KGGK Abschnitt 3.2.1]

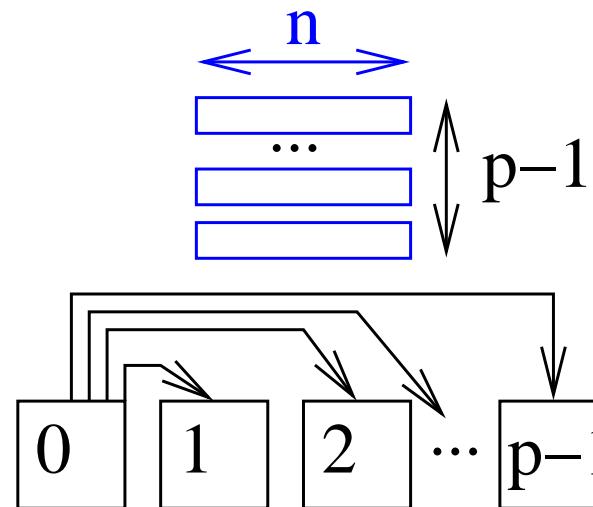
Procedure naiveBroadcast($m[1..n]$)

PE 0: **for** $i := 1$ **to** $p - 1$ **do** send m to PE i

PE $i > 0$: receive m

Zeit: $(p - 1)(nT_{\text{byte}} + T_{\text{start}})$

Alpträum bei der Implementierung skalierbarer Algorithmen



Binomialbaum-Broadcast

Procedure binomialTreeBroadcast($m[1..n]$)

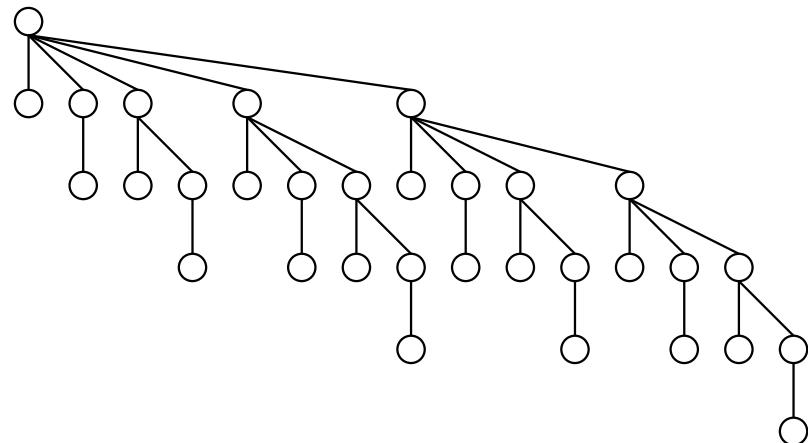
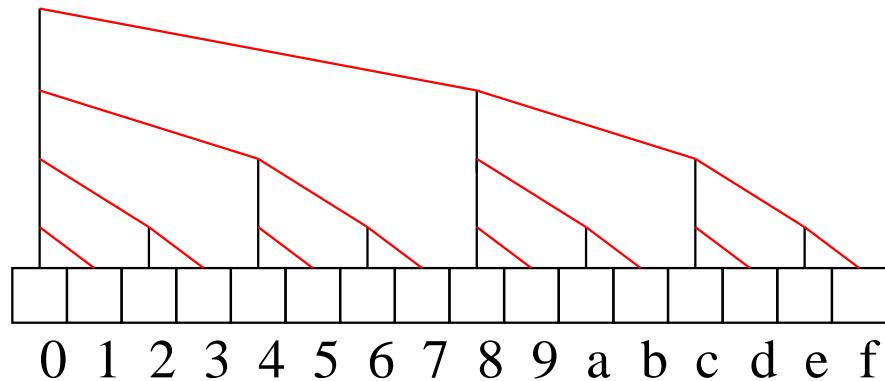
PE index $i \in \{0, \dots, p - 1\}$

//Message m located on PE 0

if $i > 0$ **then** receive m

for $k := \min\{\lceil \log n \rceil, \text{trailingZeroes}(i)\} - 1$ **downto** 0 **do**

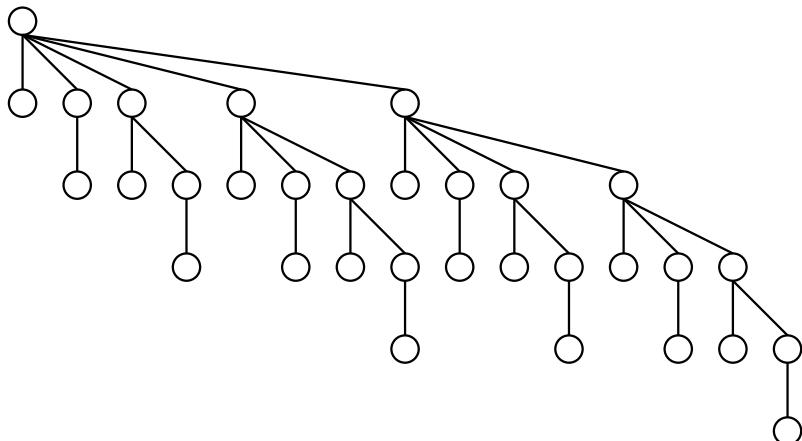
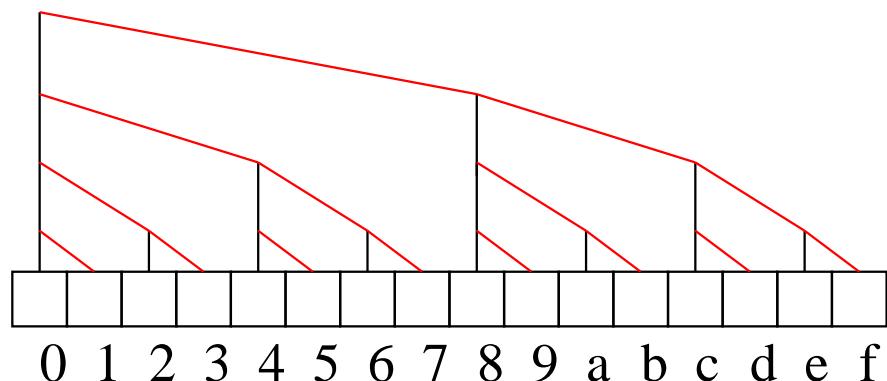
send m to PE $i + 2^k$ // noop if receiver $\geq p$



Analyse

- Zeit: $\lceil \log p \rceil (nT_{\text{byte}} + T_{\text{start}})$
- Optimal für $n = 1$
- Einbettbar in lineares Gitter

$n \cdot f(p) \rightsquigarrow n + \log p?$



Lineare Pipeline

Procedure linearPipelineBroadcast($m[1..n], k$)

PE index $i \in \{0, \dots, p - 1\}$

//Message m located on PE 0

//assume k divides n

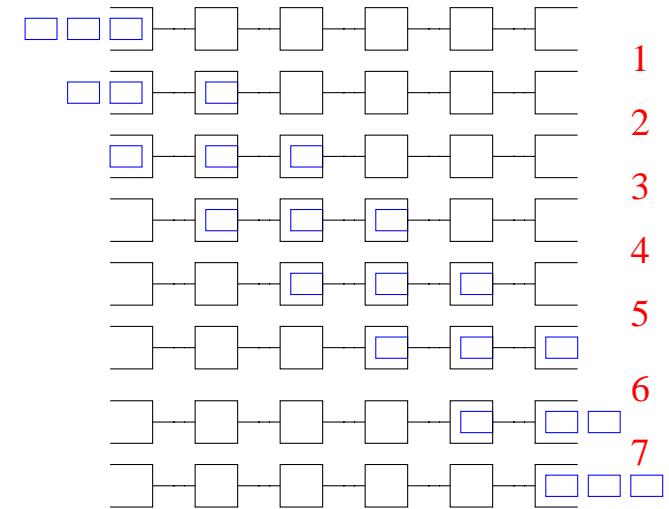
define **piece** j as $m[(j - 1)\frac{n}{k} + 1..j\frac{n}{k}]$

for $j := 1$ **to** $k + 1$ **do**

receive piece j from PE $i - 1$ // noop if $i = 0$ or $j = k + 1$

and, concurrently,

send piece $j - 1$ to PE $i + 1$ // noop if $i = p - 1$ or $j = 0$



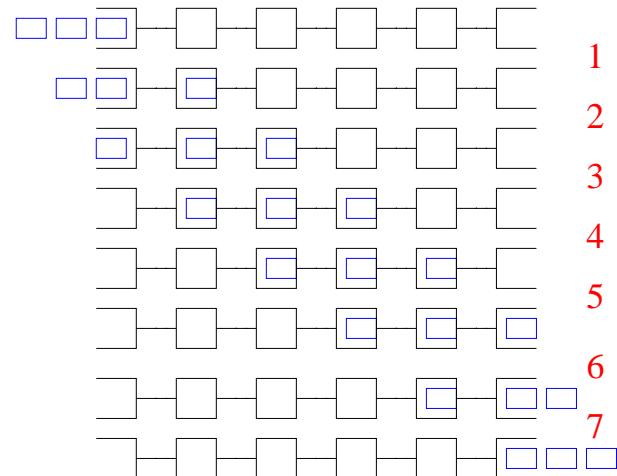
Analyse

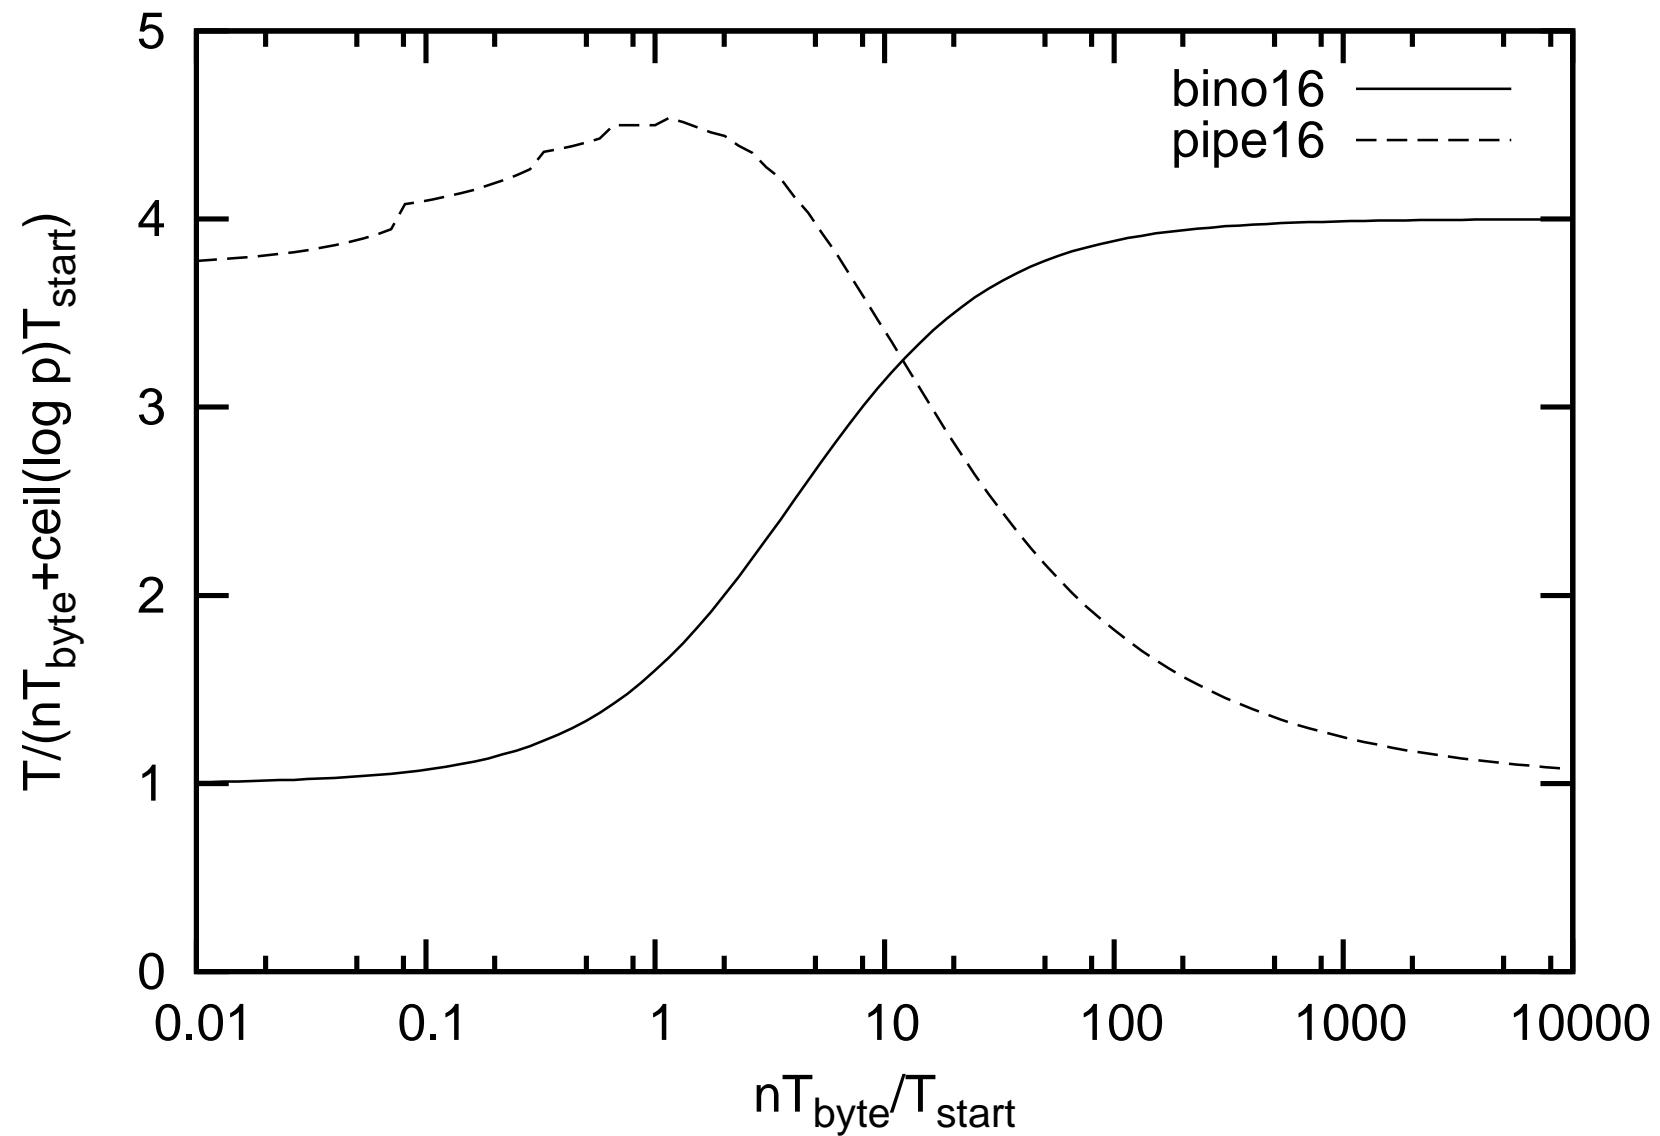
- Zeit $\frac{n}{k} T_{\text{byte}} + T_{\text{start}}$ pro Schritt
(\neq Iteration)
- $p - 1$ Schritte bis erstes Paket ankommt
- Dann 1 Schritte pro weiteres Paket

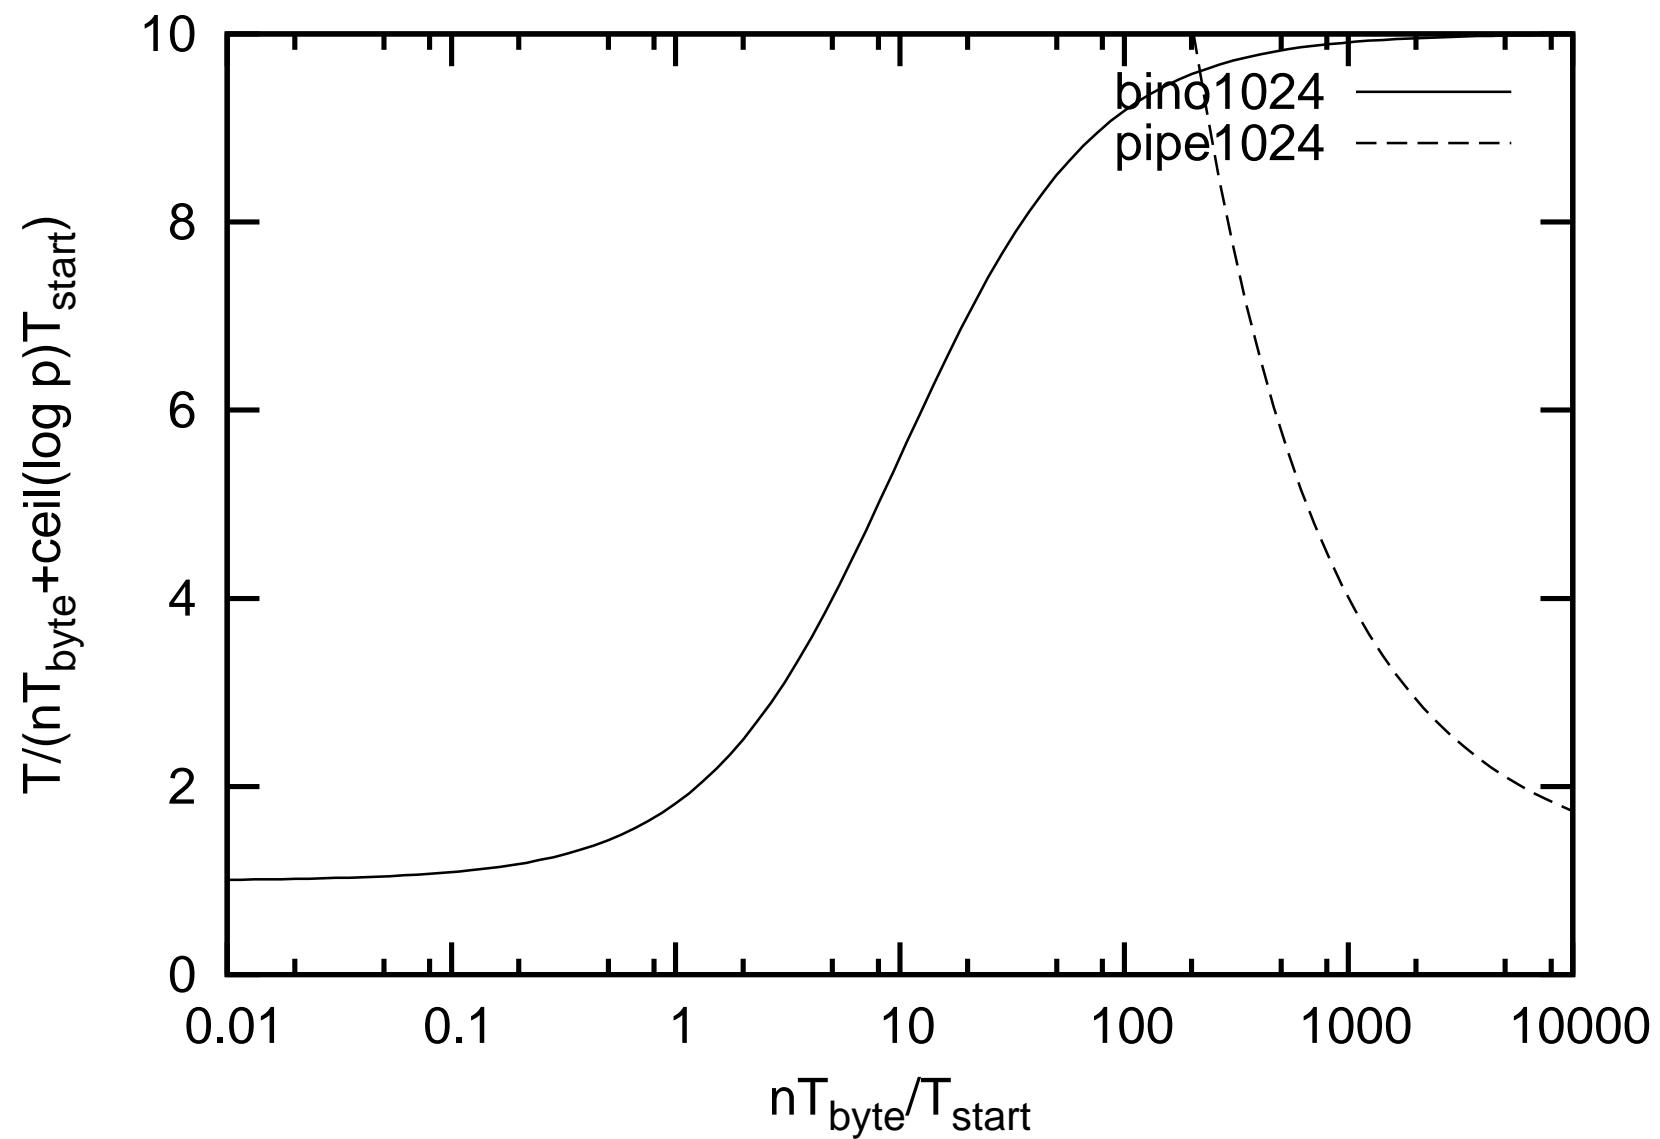
$$T(n, p, k): \left(\frac{n}{k} T_{\text{byte}} + T_{\text{start}} \right) (p + k - 2))$$

optimales k : $\sqrt{\frac{n(p-2)T_{\text{byte}}}{T_{\text{start}}}}$

$$T^*(n, p): \approx nT_{\text{byte}} + pT_{\text{start}} + 2\sqrt{npT_{\text{start}}T_{\text{byte}}}$$







Diskussion

- Lineares Pipelining ist optimal für festes p und $n \rightarrow \infty$
- Aber für großes p braucht man extrem grosse Nachrichten

$T_{\text{start}} p \rightsquigarrow T_{\text{start}} \log p?$

Procedure binaryTreePipelinedBroadcast($m[1..n], k$)

//Message m located on **root**, assume k divides n

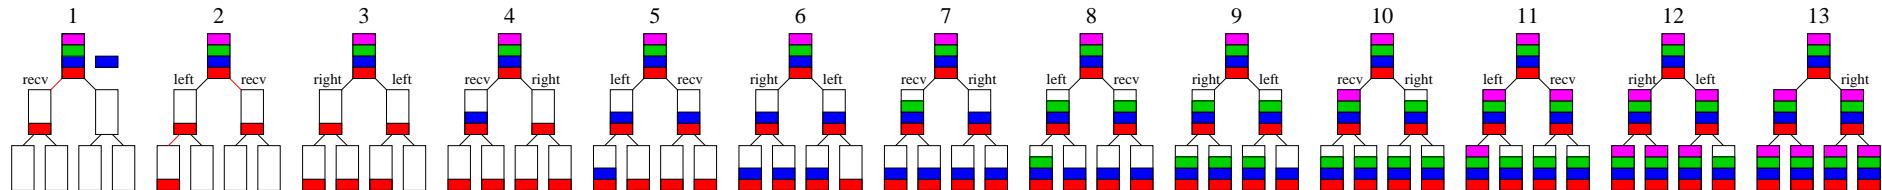
define **piece** j as $m[(j - 1)\frac{n}{k} + 1..j\frac{n}{k}]$

for $j := 1$ **to** k **do**

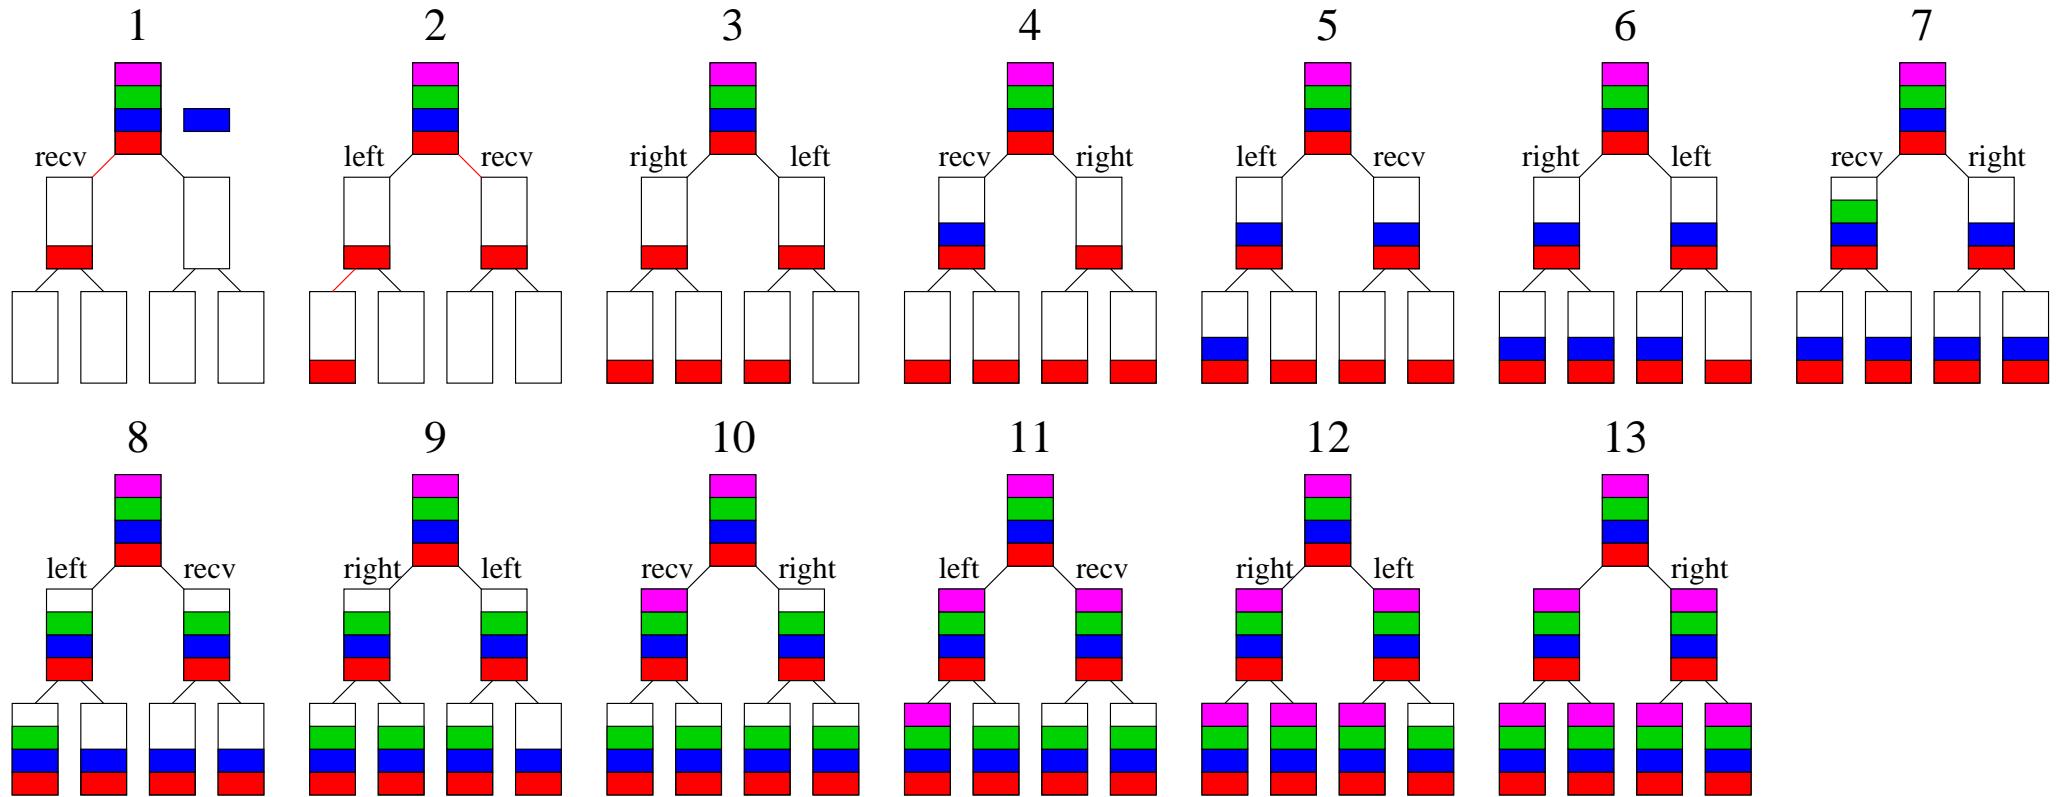
if **parent** exists **then** receive piece j

if **left child** ℓ exists **then** send piece j to ℓ

if **right child** r exists **then** send piece j to r



Beispiel



Analyse

- Zeit $\frac{n}{k}T_{\text{byte}} + T_{\text{start}}$ pro Schritt (\neq Iteration)
 - $2j$ Schritte bis erstes Paket **Schicht j** erreicht
 - Wieviele Schichten? $d := \lfloor \log p \rfloor$
-
- Dann **3** Schritte pro weiteres Paket

Insgesamt: $T(n, p, k) := (2d + 3(k - 1)) \left(\frac{n}{k}T_{\text{byte}} + T_{\text{start}} \right)$

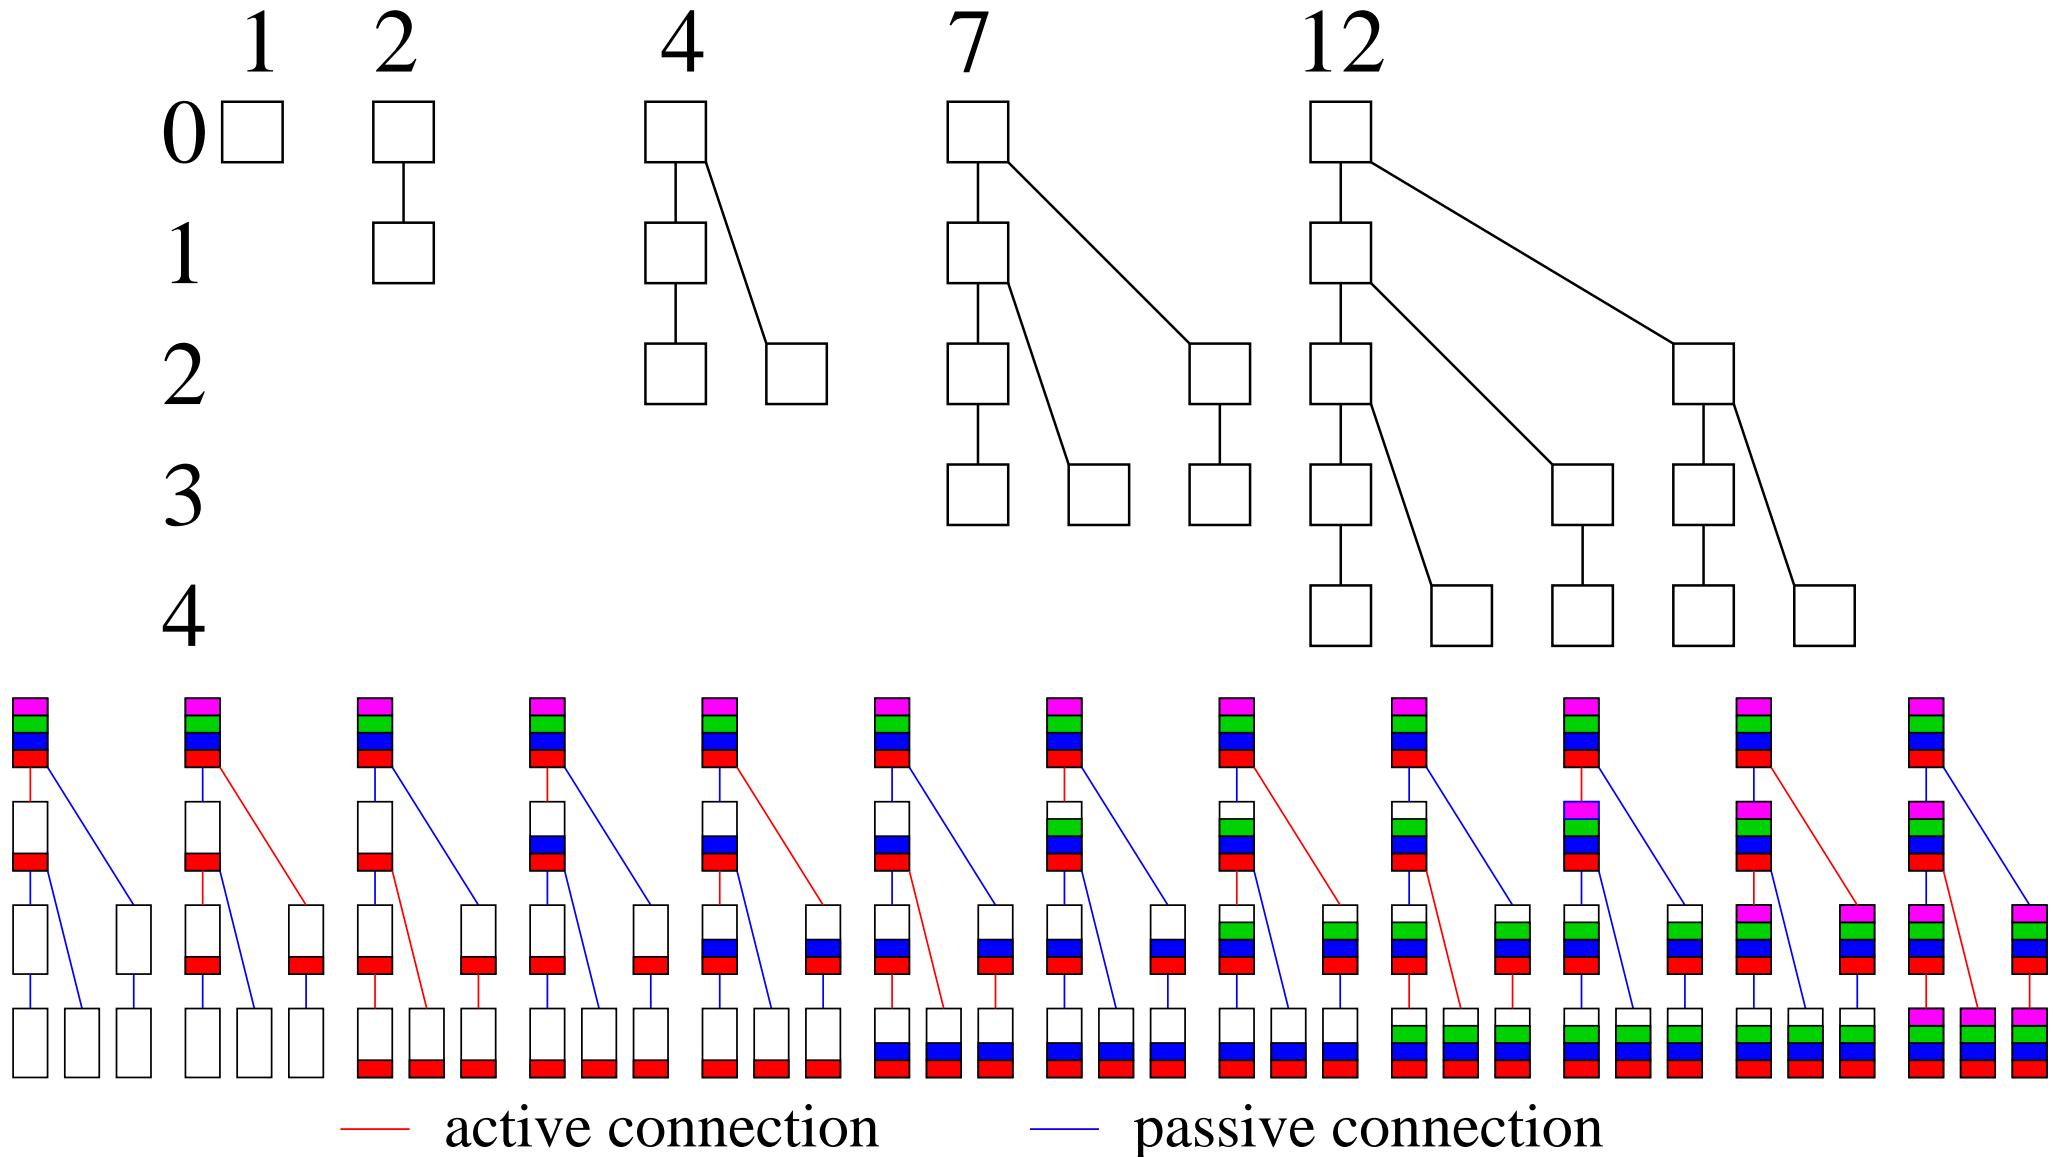
optimales k : $\sqrt{\frac{n(2d - 3)T_{\text{byte}}}{3T_{\text{start}}}}$

Analyse

- Zeit $\frac{n}{k}T_{\text{byte}} + T_{\text{start}}$ pro Schritt (\neq Iteration)
- $d := \lfloor \log p \rfloor$ Schichten
- Insgesamt: $T(n, p, k) := (2d + 3(k - 1)) \left(\frac{n}{k}T_{\text{byte}} + T_{\text{start}} \right)$
- optimales k : $\sqrt{\frac{n(2d - 3)T_{\text{byte}}}{3T_{\text{start}}}}$

eingesetzt: $T^*(n, p) = 2dT_{\text{start}} + 3nT_{\text{byte}} + \mathcal{O}\left(\sqrt{ndT_{\text{start}}T_{\text{byte}}}\right)$

Fibonacci-Bäume



Analyse

- Zeit $\frac{n}{k} T_{\text{byte}} + T_{\text{start}}$ pro Schritt (\neq Iteration)
- j Schritte bis erstes Paket **Schicht j** erreicht
- Wieviele PEs p_j mit Schicht $0..j$?

$p_0 = 1, p_1 = 2, p_j = p_{j-2} + p_{j-1} + 1 \rightsquigarrow$ ask Maple,

```
rsolve(p(0)=1, p(1)=2, p(i)=p(i-2)+p(i-1)+1, p(i));
```

$$p_j \approx \frac{3\sqrt{5} + 5}{5(\sqrt{5} - 1)} \Phi^j \approx 1.89\Phi^j$$

mit $\Phi = \frac{1+\sqrt{5}}{2}$ (goldener Schnitt)

$\rightsquigarrow d \approx \log_{\Phi} p$ Schichten

insgesamt: $T^*(n, p) = \textcolor{red}{dT}_{\text{start}} + 3nT_{\text{byte}} + \mathcal{O}\left(\sqrt{ndT_{\text{start}}T_{\text{byte}}}\right)$

Procedure fullDuplexBinaryTreePipelinedBroadcast($m[1..n], k$)

//Message m located on **root**, assume k divides n

define **piece** j as $m[(j - 1)\frac{n}{k} + 1..j\frac{n}{k}]$

for $j := 1$ **to** $k + 1$ **do**

receive

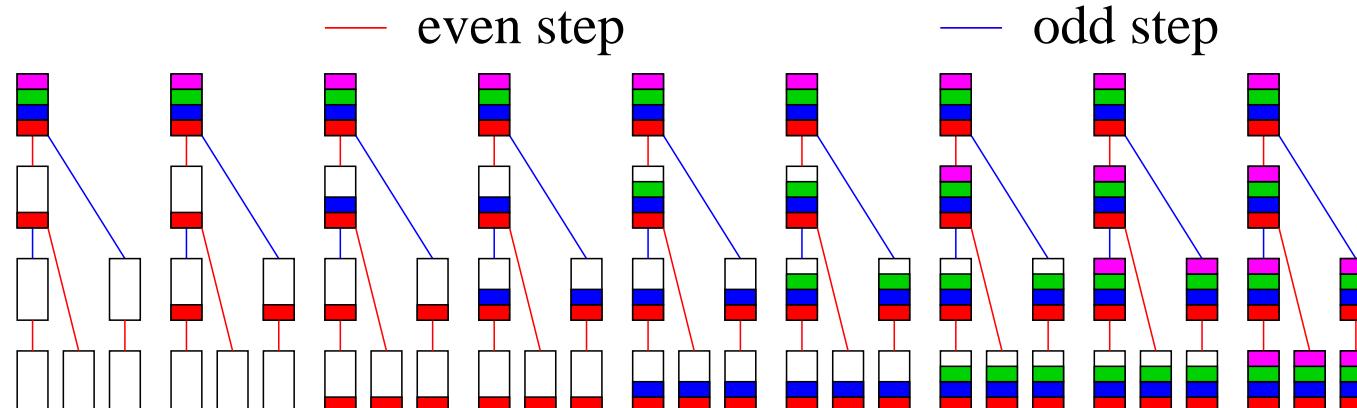
 piece j from parent // noop for root or $j = k + 1$

and, concurrently, **send** piece $j - 1$ to right child

// noop if no such child or $j = 1$

send piece j to left child

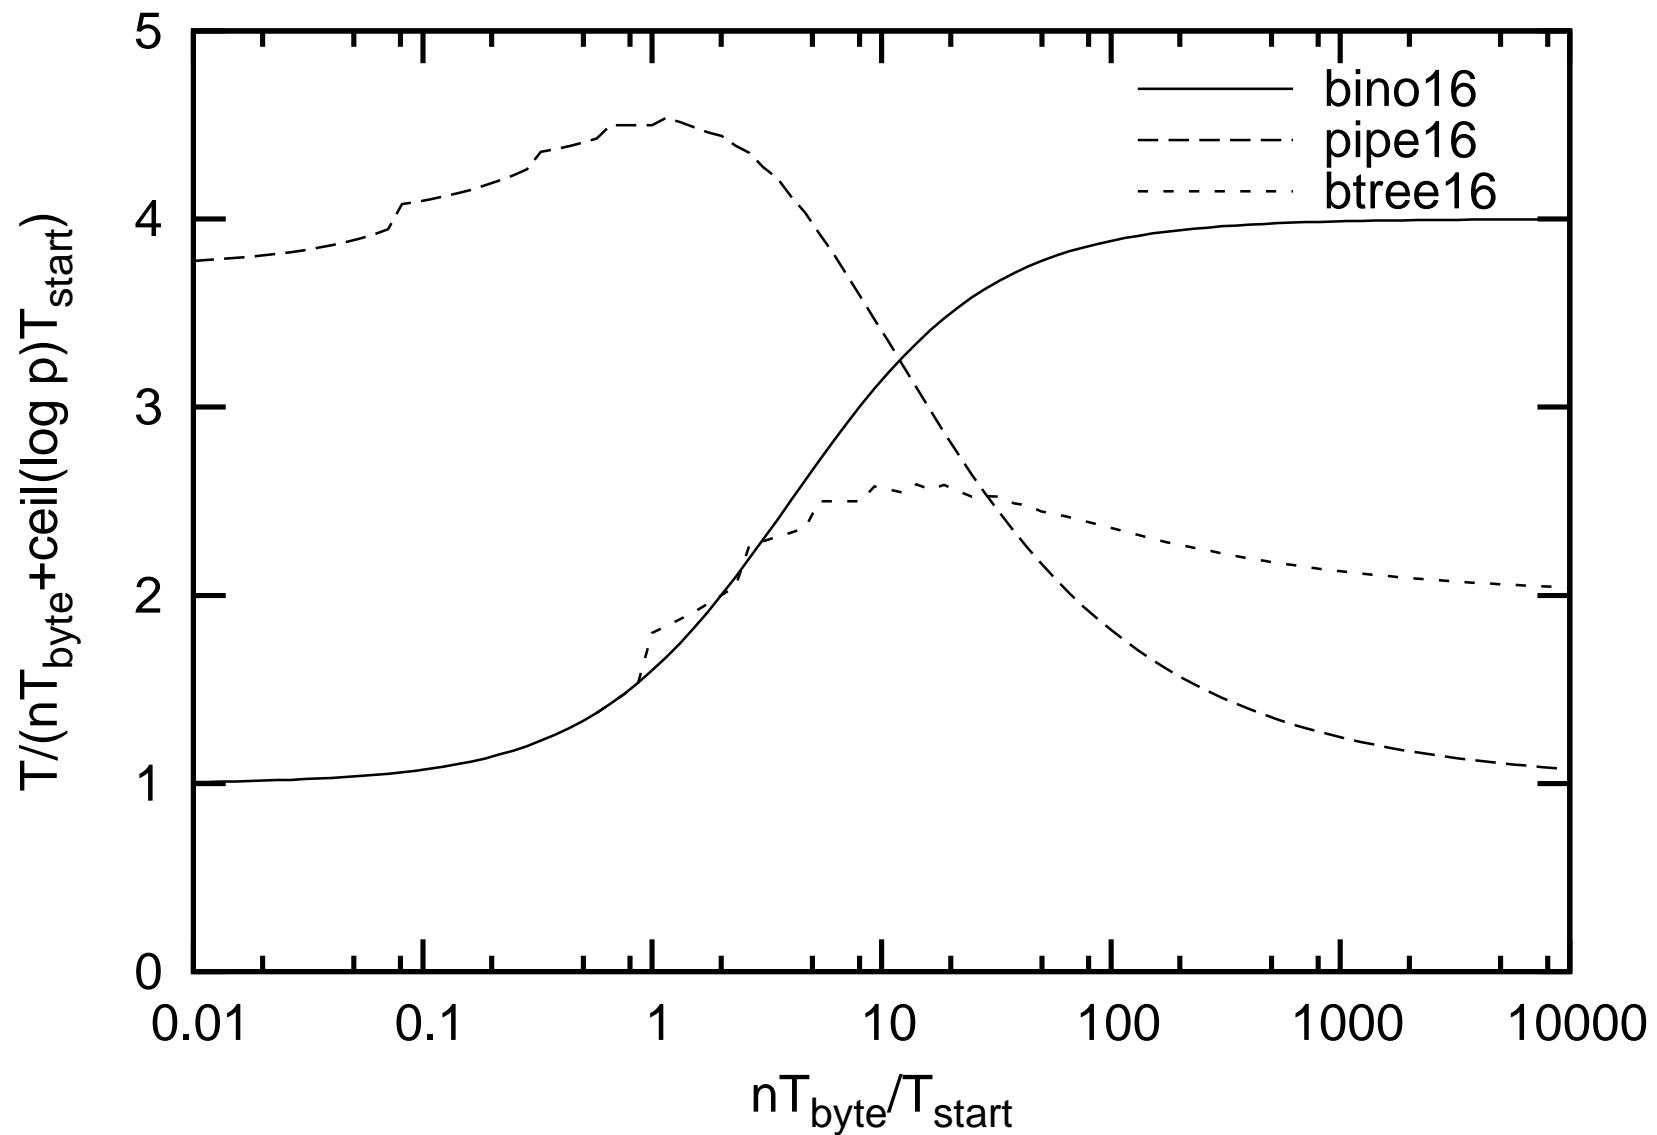
// noop if no such child or $j = k + 1$

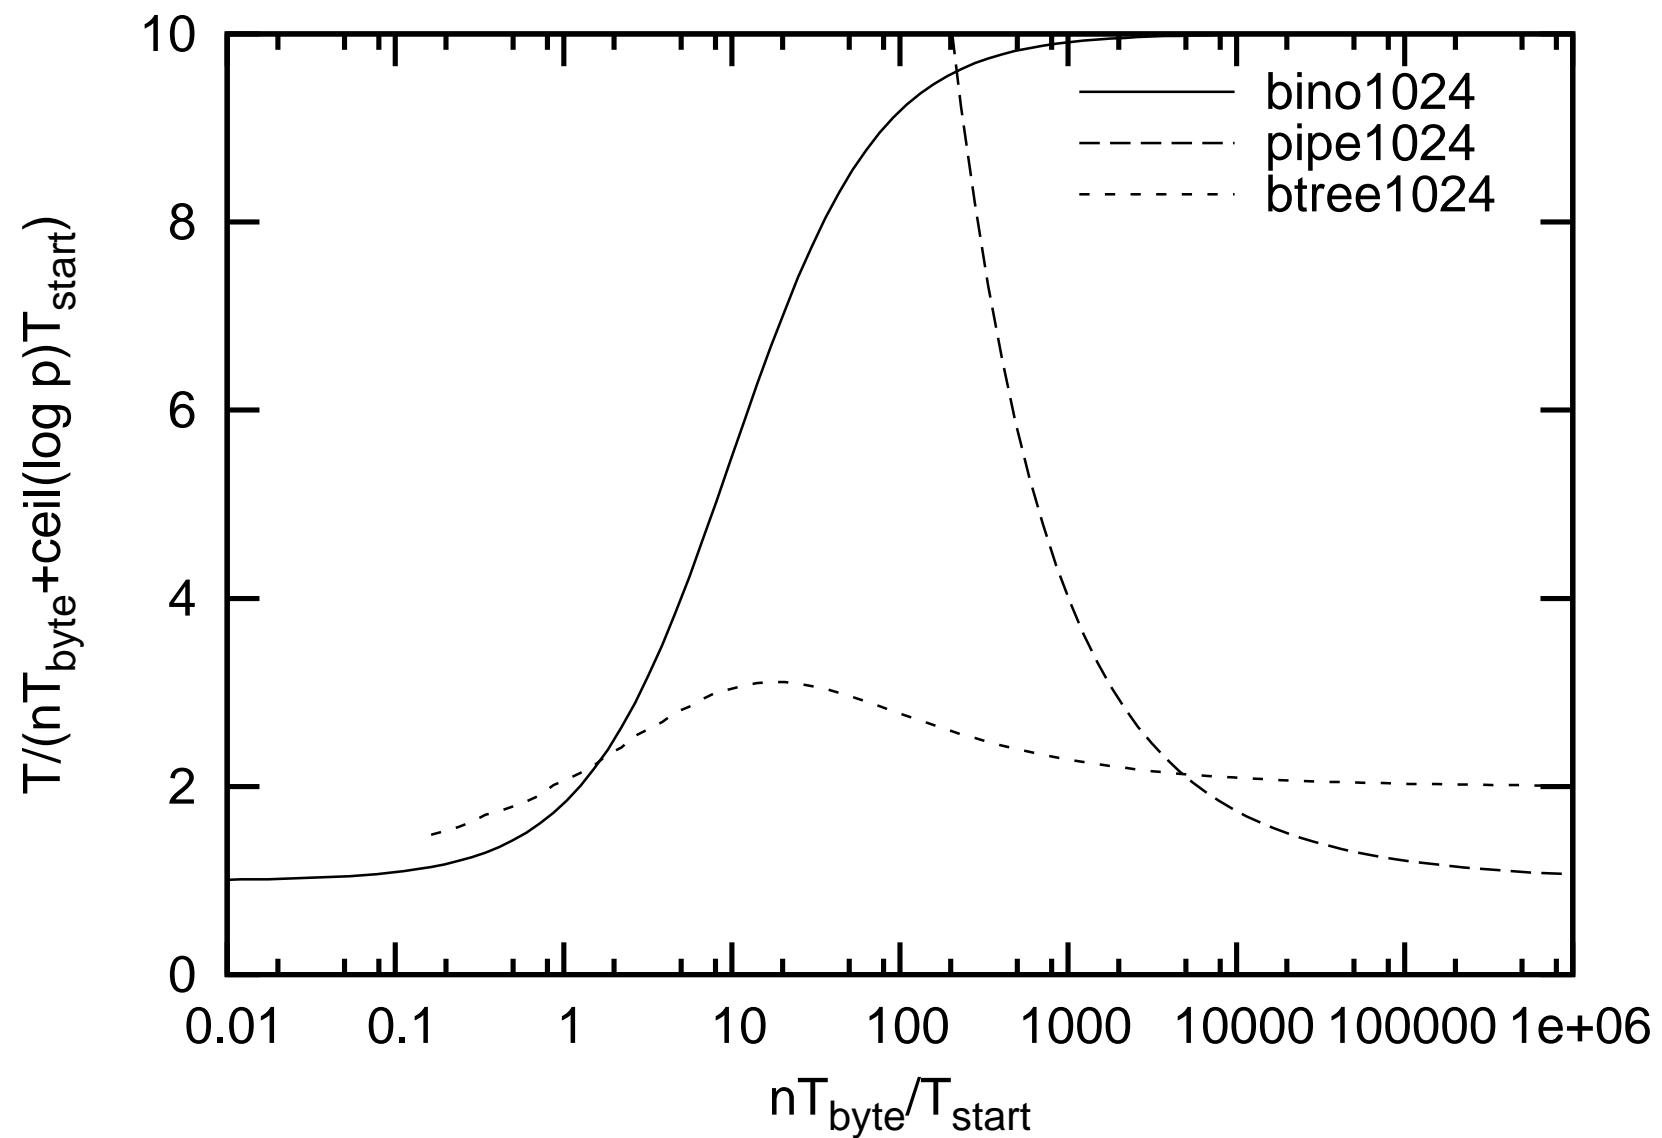


Analyse

- Zeit $\frac{n}{k} T_{\text{byte}} + T_{\text{start}}$ pro Schritt
- j Schritte bis erstes Paket **Schicht j** erreicht
- $d \approx \log_{\Phi} p$ Schichten
- Dann **2** Schritte pro weiteres Paket

insgesamt: $T^*(n, p) = dT_{\text{start}} + \cancel{2n}T_{\text{byte}} + \mathcal{O}\left(\sqrt{ndT_{\text{start}}T_{\text{byte}}}\right)$





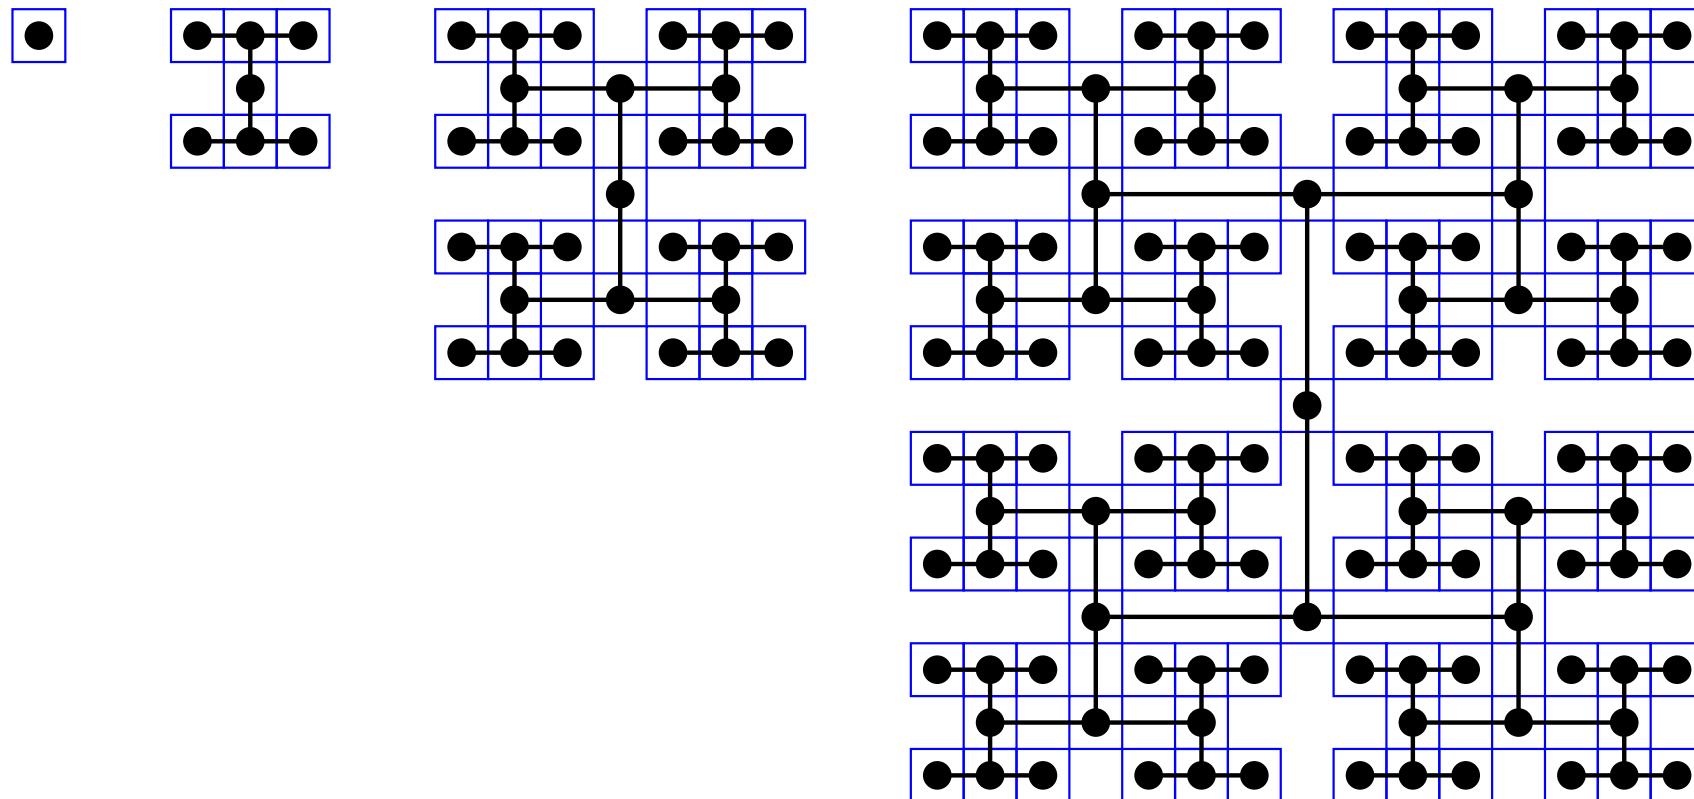
Diskussion

Fibonacci trees sind ein guter Kompromiss für alle n, p .

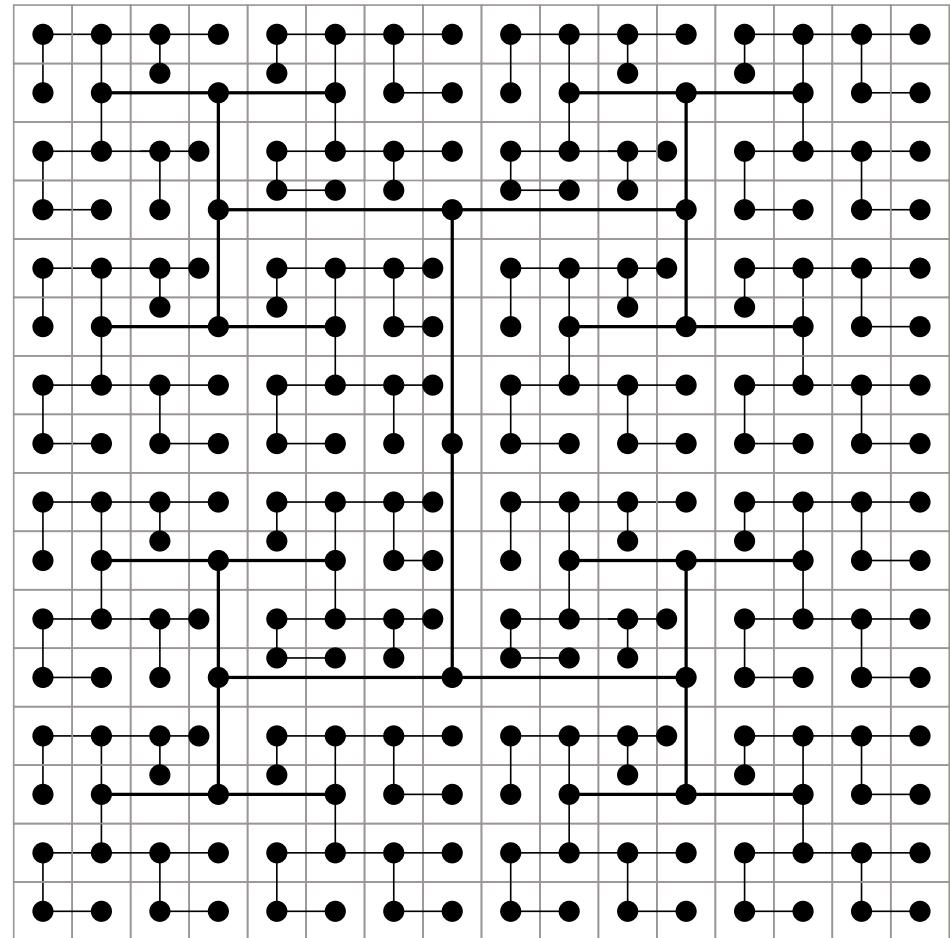
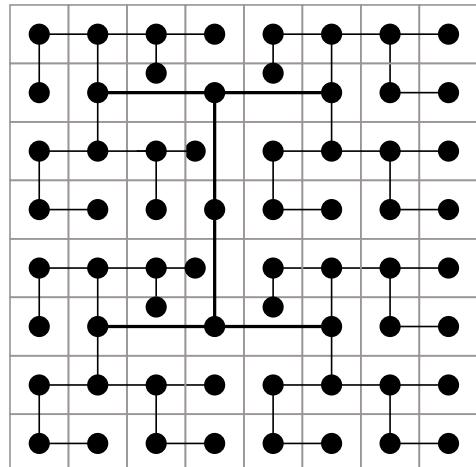
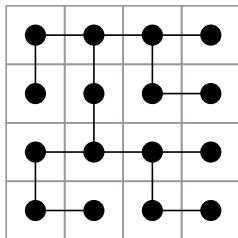
Allgemeine p :

nächstgrößeren Baum nehmen und dann Teilbaum weglassen.

H-Trees



H-Trees

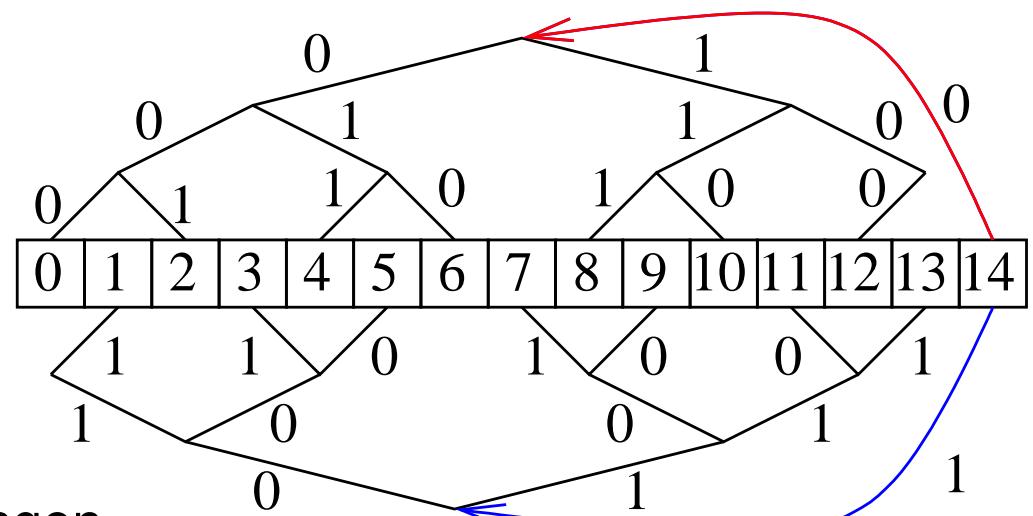


Nachteile baumbasierter Broadcasts

- **Blätter** empfangen nur Ihre Daten
und tragen sonst nichts zur Verbreitung der Daten bei
- **Innere Knoten** senden mehr als sie empfangen
~~> full-duplex Kommunikation nicht ausgereizt

23-Broadcast: Two T(h)rees for the Price of One

- Binary-Tree-Broadcasts über zwei Bäume A und B gleichzeitig
- Innere Knoten von A sind Blätter von B und umgekehrt
- Pro Doppelschritt:
Ein Paket als Blatt empfangen + Ein Paket als innerer Knoten empfangen und weiterleiten.
d.h. 2 Pakete senden und empfangen

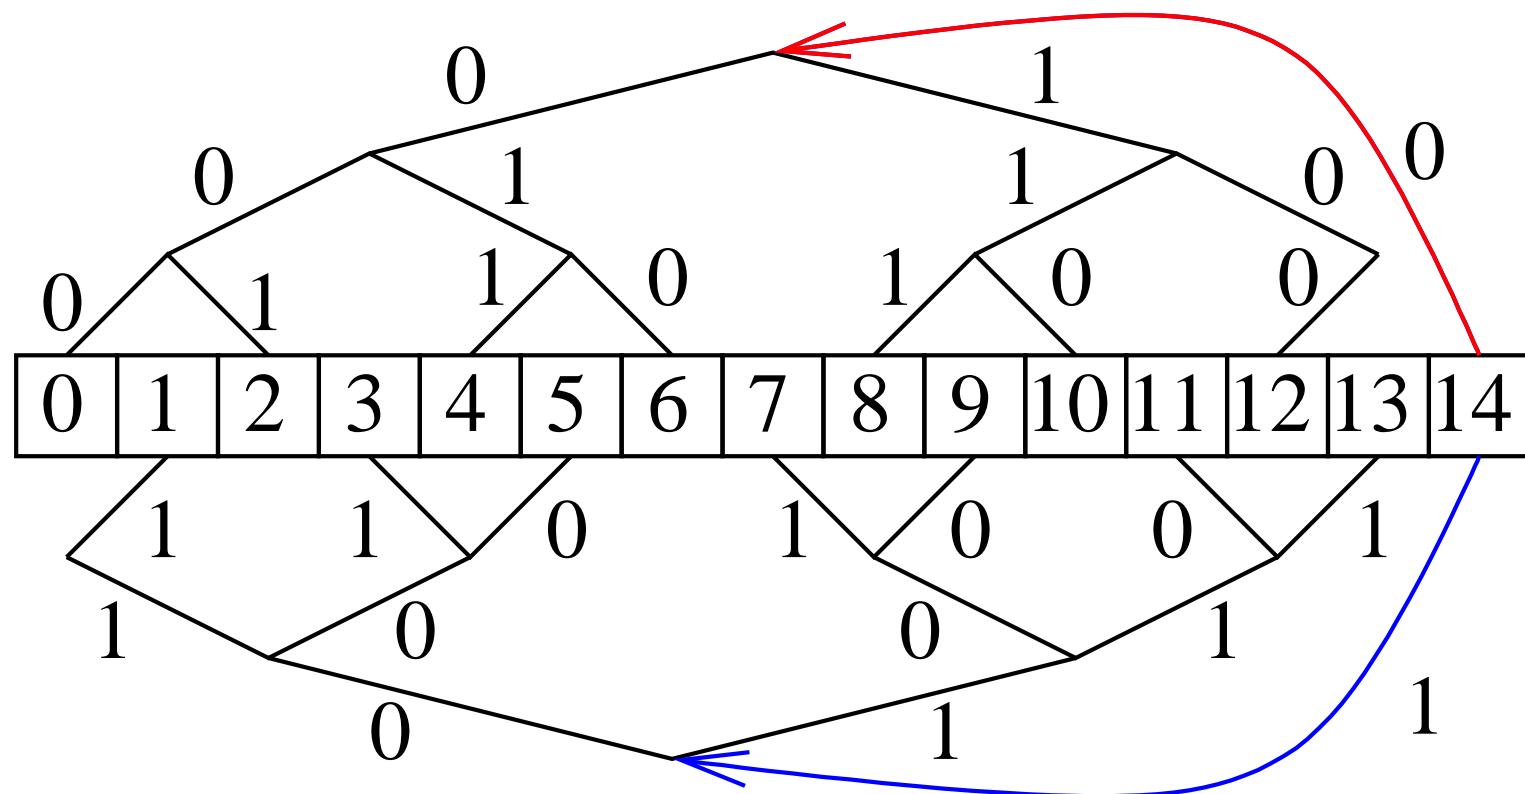


Root Process

for $j := 1$ **to** k **step** 2 **do**

send piece $j + 0$ along edge labelled 0

send piece $j + 1$ along edge labelled 1



Other Processes,

Wait for first piece to arrive

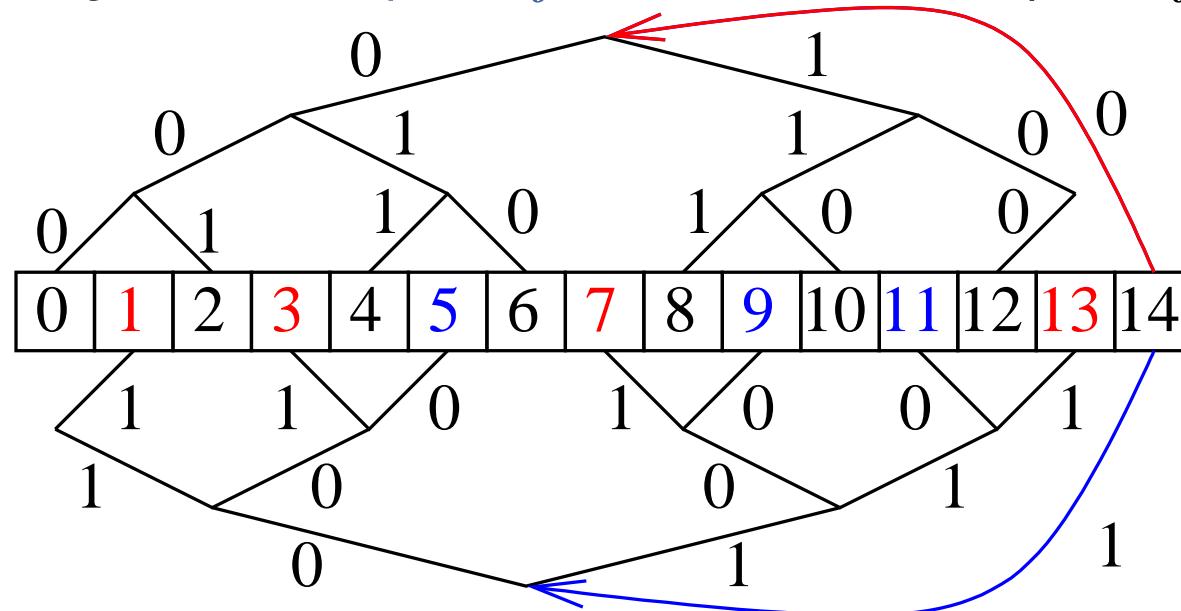
if it comes from the upper tree over an edge labelled b **then**

$\Delta := 2 \cdot$ distance of the node from the bottom in the upper tree

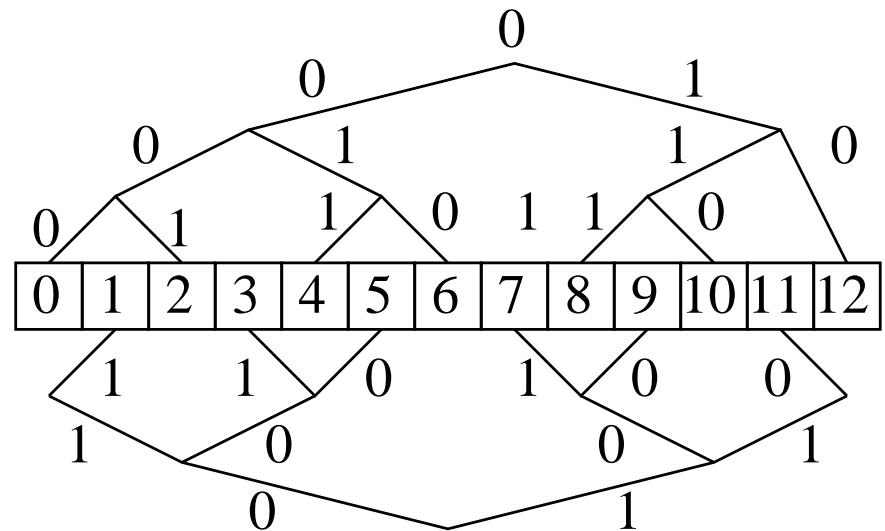
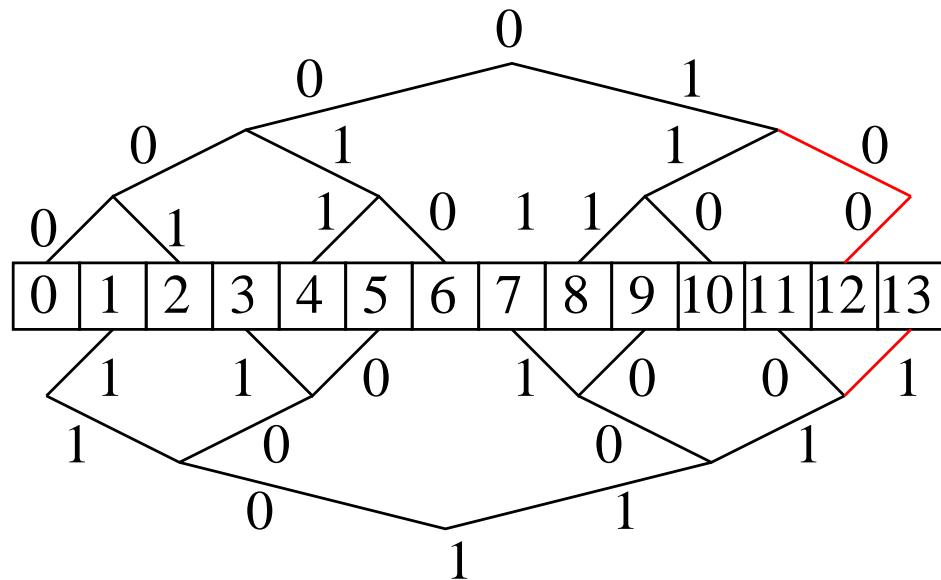
for $j := 1$ **to** $k + \Delta$ **step 2 do**

along b -edges: receive piece j and send piece $j - 2$

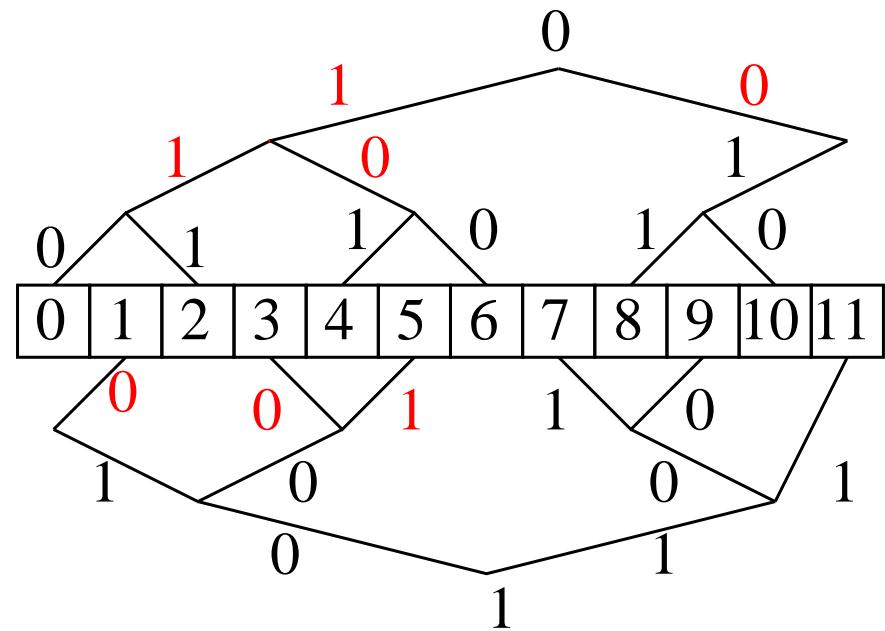
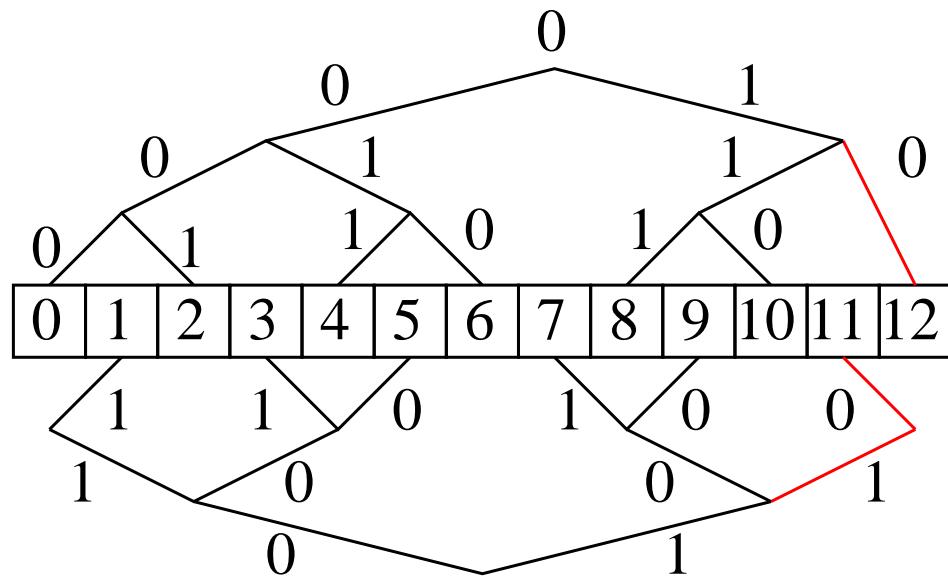
along $1 - b$ -edges: receive piece $j + 1 - \Delta$ and send piece j



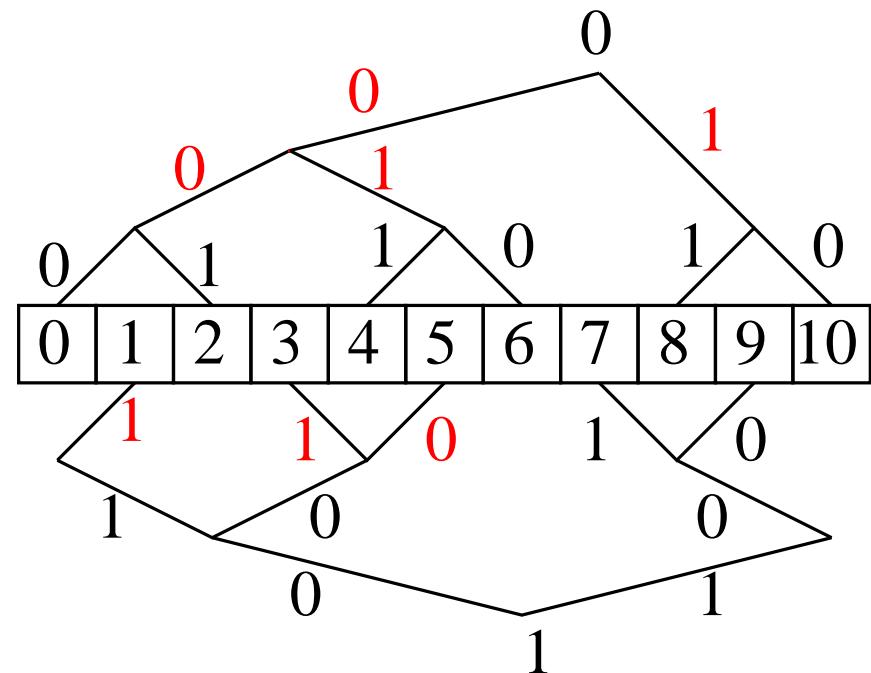
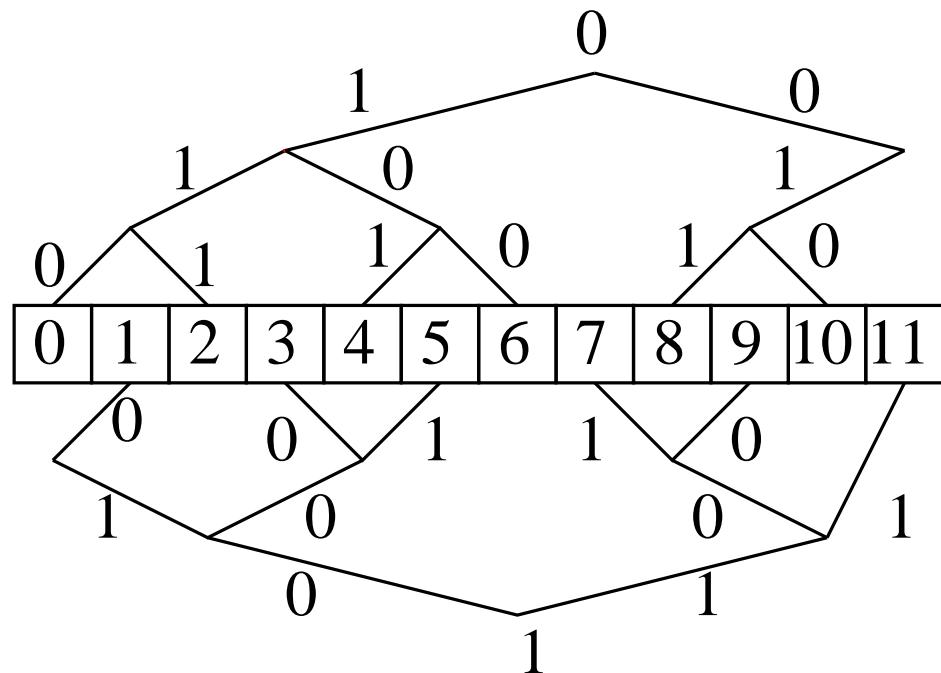
Beliebige Prozessorzahl



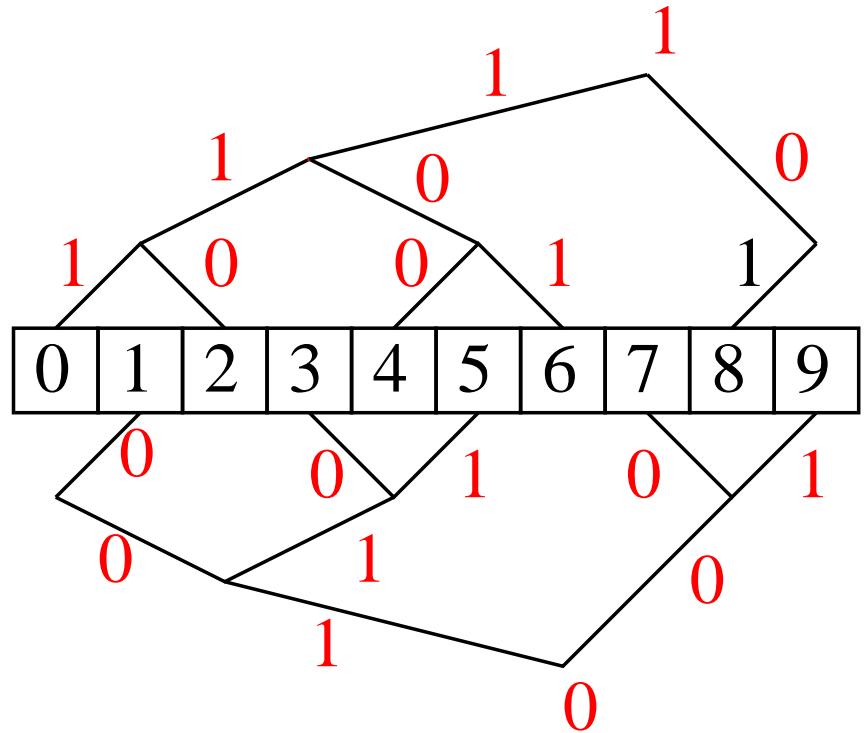
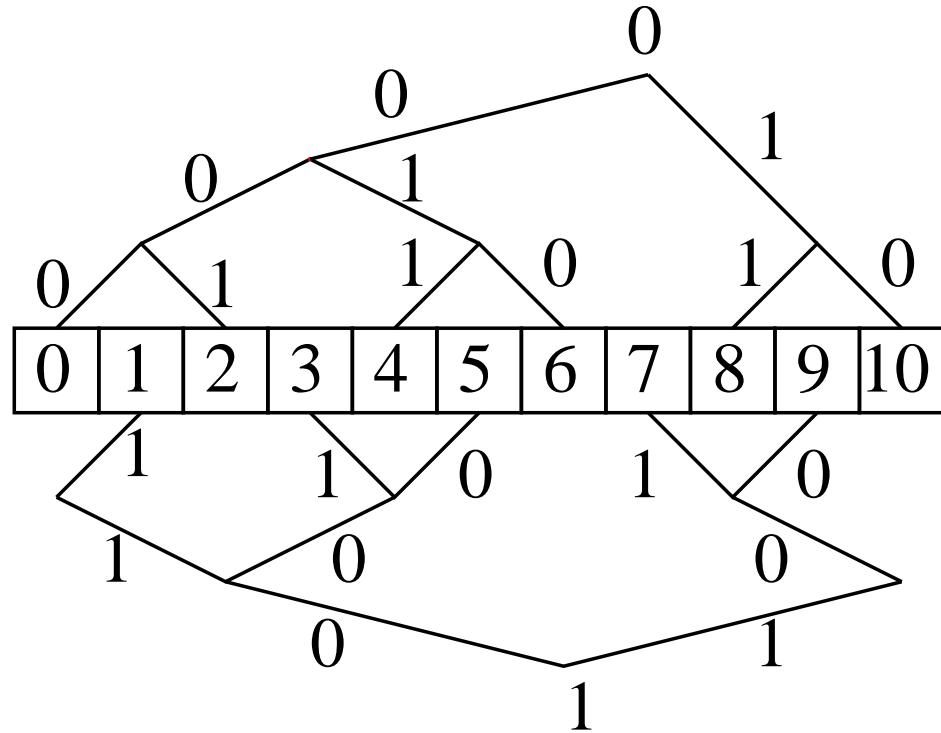
Beliebige Prozessorzahl



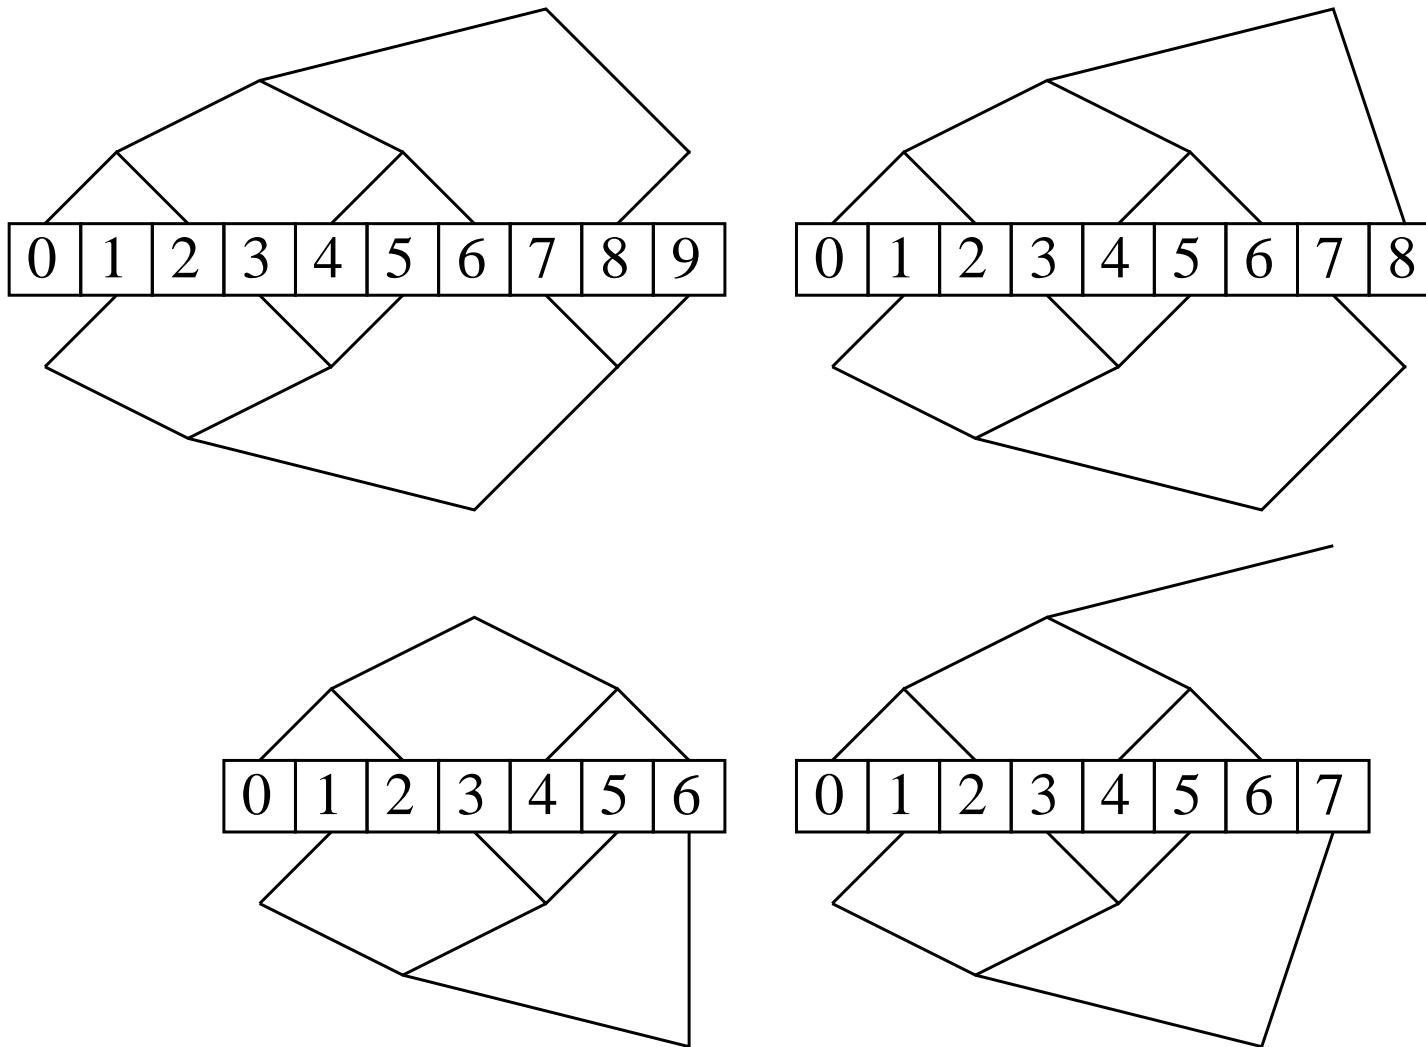
Beliebige Prozessorzahl



Beliebige Prozessorzahl



Beliebige Prozessorzahl



Aufbau der Bäume

Fall $p = 2^h - 1$: Oberer Baum + Unterer Baum + Wurzel

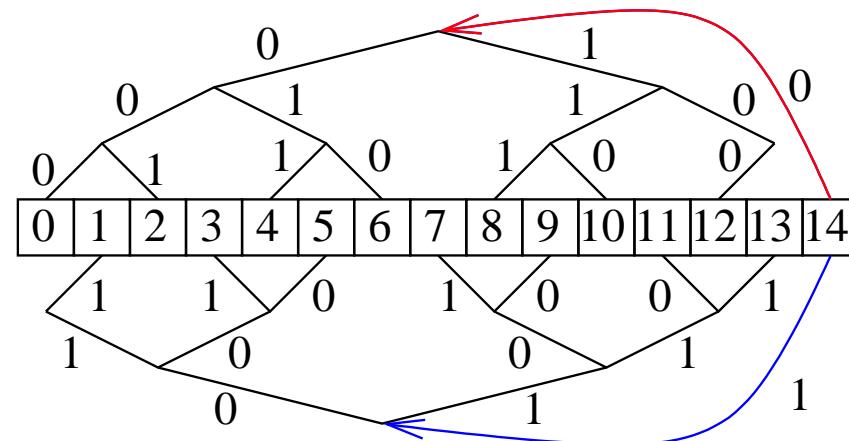
Oberer Baum: Vollst. Binärbaum der Höhe $h - 1$, – rechtes Blatt

Unterer Baum: Vollst. Binärbaum der Höhe $h - 1$, – linkes Blatt

Unterer Baum \approx Oberer Baum um eins verschoben

Innere Knoten oberer Baum = Blätter unterer Baum.

Innere Knoten unterer Baum = Blätter oberer Baum.



Aufbau kleinerer Bäume (ohne Wurzel)

invariant : letzter Knoten hat Ausgangsgrad 1 in Baum x

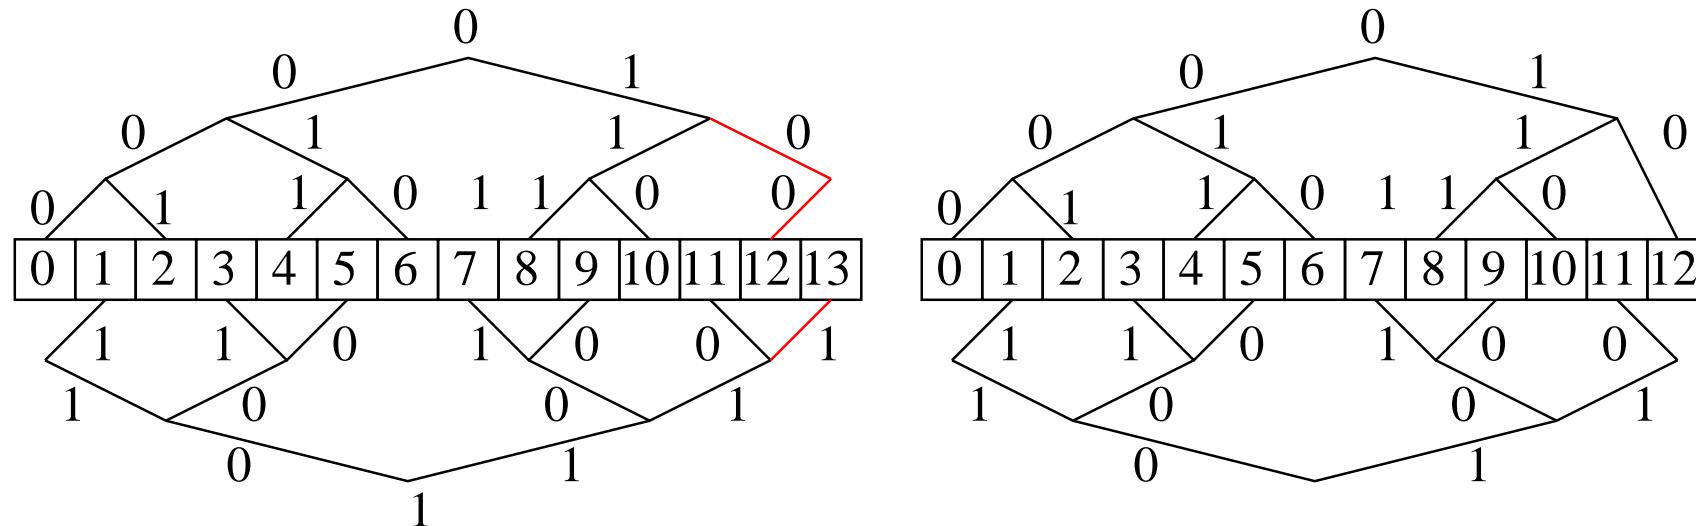
invariant : letzter Knoten hat Ausgangsgrad 0 in Baum \bar{x}

$p \rightsquigarrow p - 1$:

Entferne letzten Knoten:

rechter Knoten in x hat jetzt Grad 0

rechter Knoten in \bar{x} hat jetzt Grad 1



Kanten färben

Betrachte den bipartiten Graphen

$$B = (\{s_0, \dots, s_{p-1}\} \cup \{r_0, \dots, r_{p-2}\}, E).$$

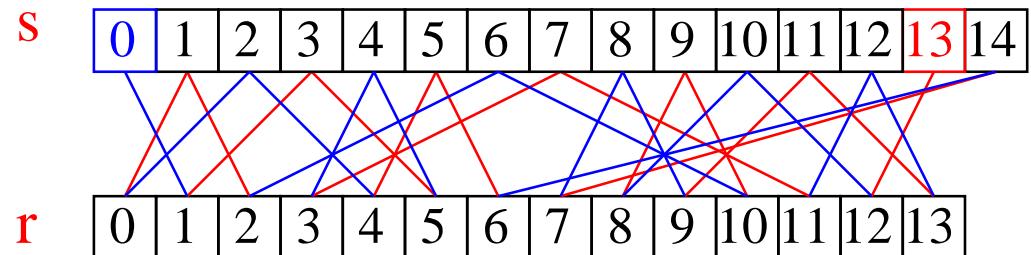
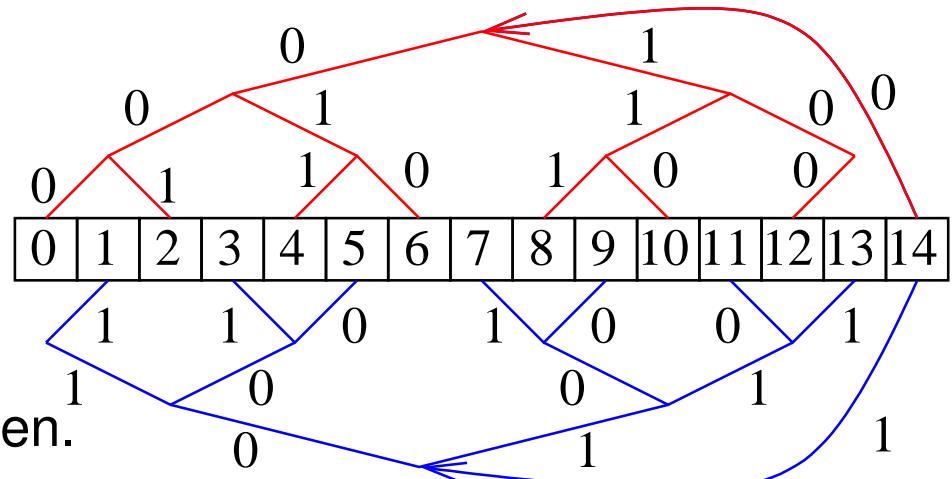
s_i : Senderrolle von PE i .

r_i : Empfängerrolle von PE i .

$2 \times$ Grad 1. Sonst alles Grad 2.

$\Rightarrow B$ ist ein Pfad plus gerade Kreise.

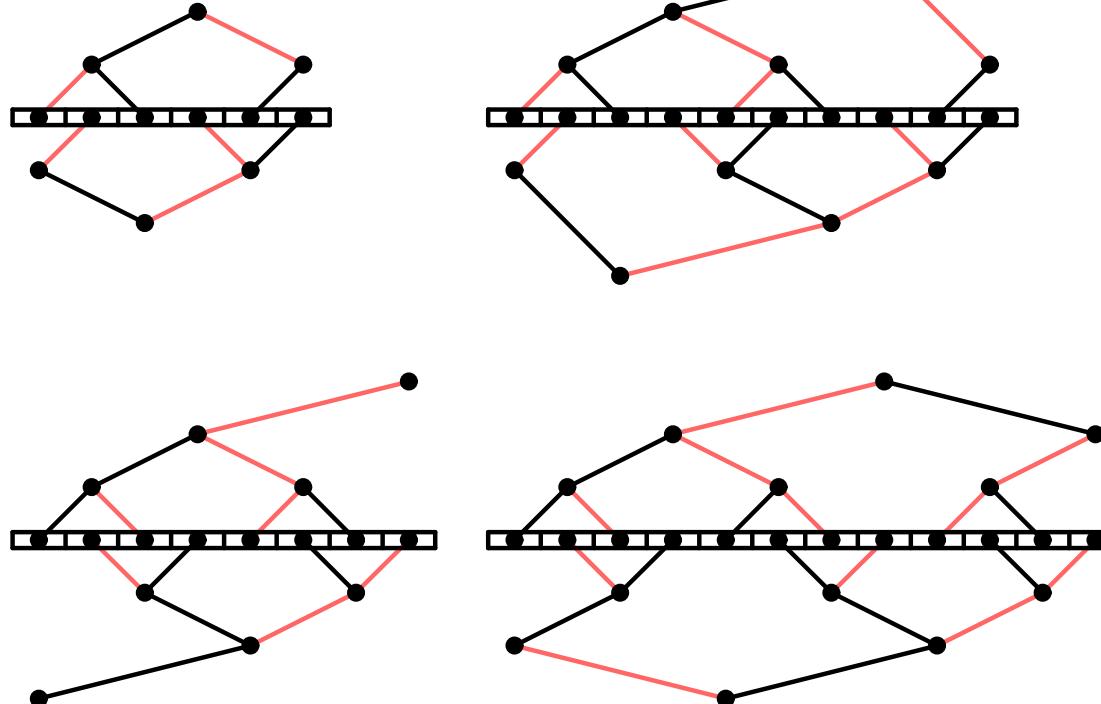
Kanten abwechselnd mit 0 und 1 färben.



Offene Frage: Parallel Färbung ?

- In Zeit $\text{Polylog}(p)$ mittels **list ranking**.
(leider nicht praktikabel für kleine Eingaben)
- Schnelle explizite Berechnung $\text{color}(i, p)$ ohne Kommunikation ?

Mirror layout:



Jochen Speck's Lösung

//Compute color of edge entering node i in the upper tree.

// h is a lower bound on the height of node i .

Function **inEdgeColor**(p, i, h)

if i is the root of T_1 **then return** 1

while i bitand $2^h = 0$ **do** $h++$ // compute height

$i' := \begin{cases} i - 2^h & \text{if } 2^{h+1} \text{ bitand } i = 1 \vee i + 2^h > p \\ i + 2^h & \text{else} \end{cases}$ // compute parent of i

return **inEdgeColor**(p, i', h) xor ($p/2 \bmod 2$) xor [$i' > i$]

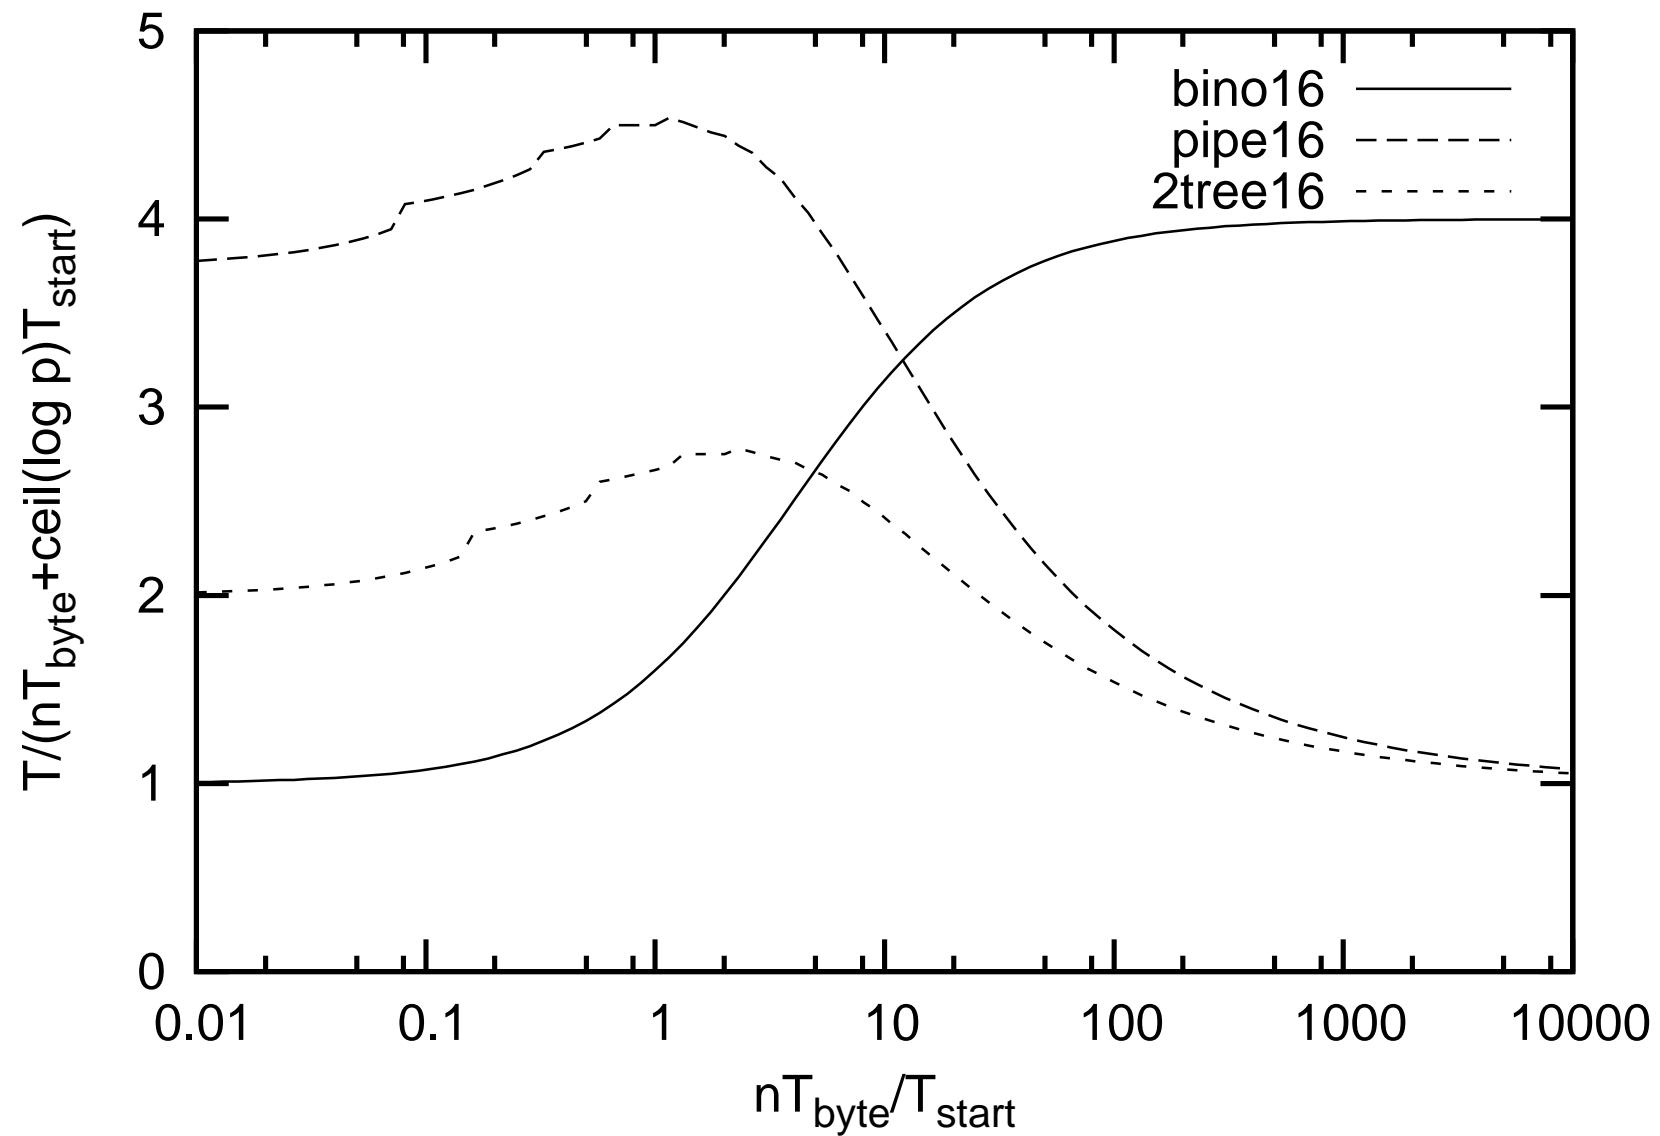
Analyse

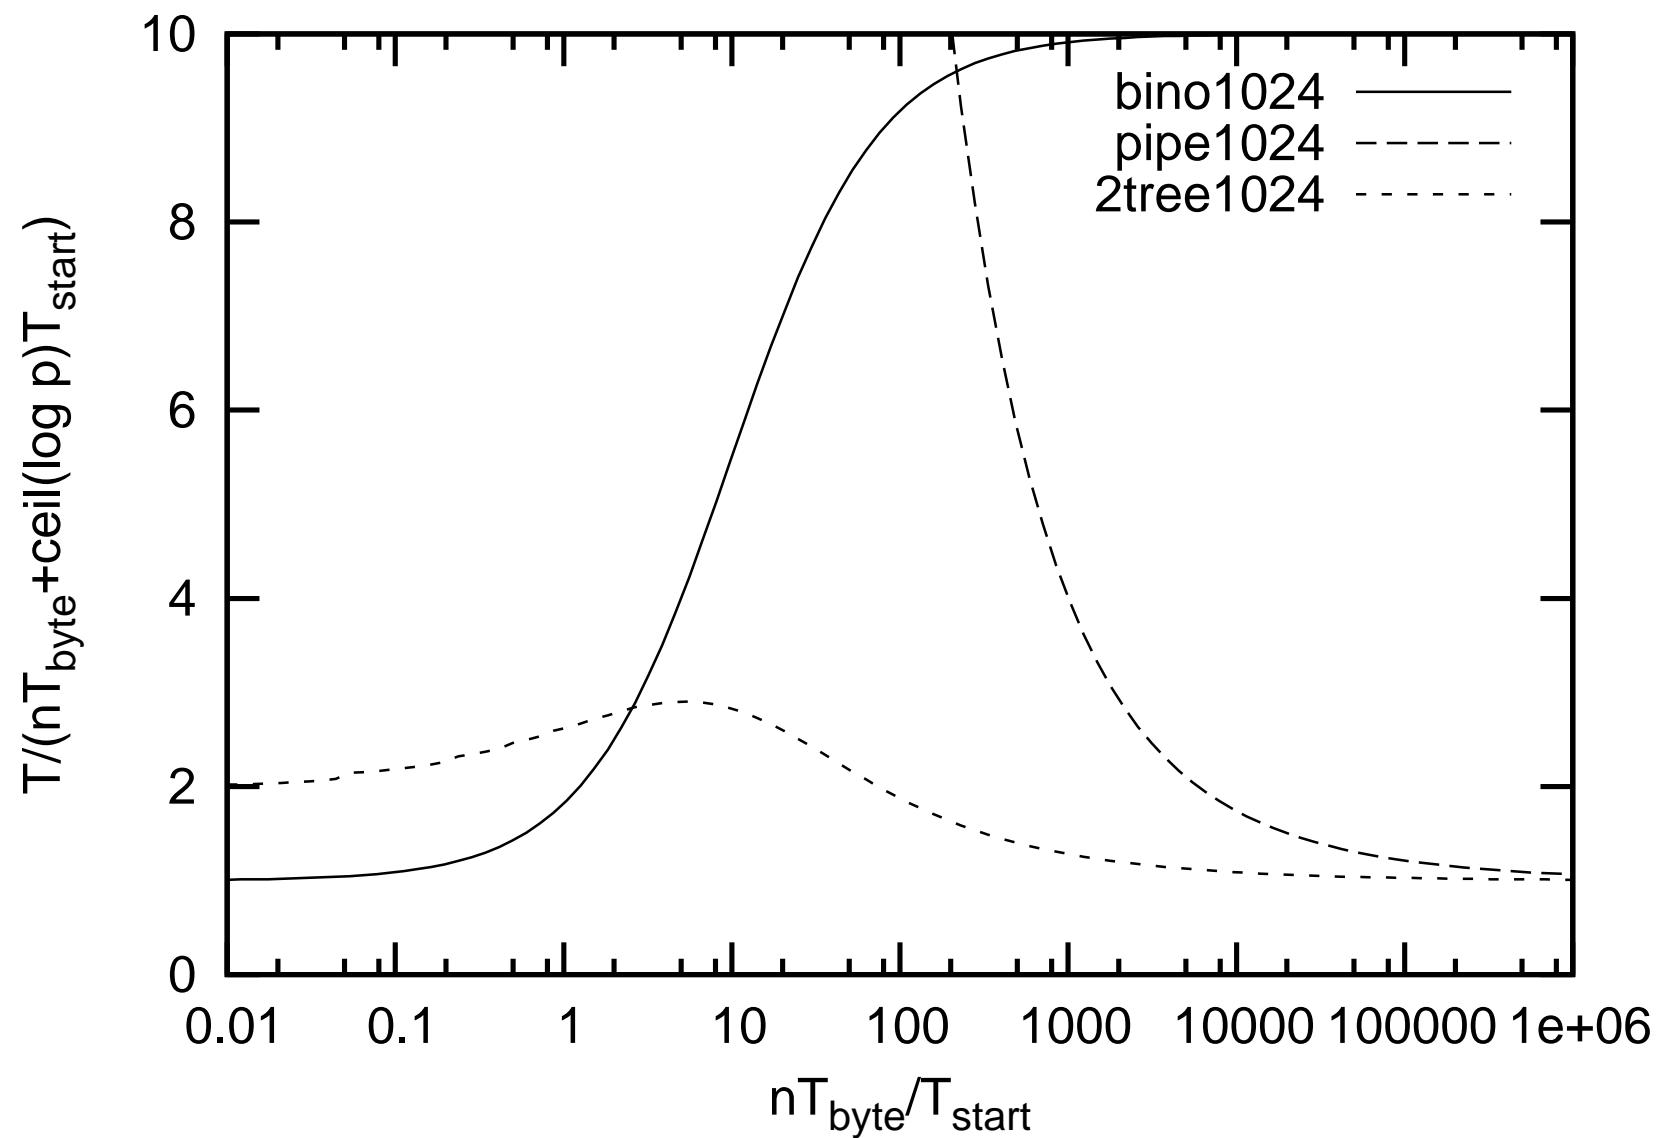
- Zeit $\frac{n}{k}T_{\text{byte}} + T_{\text{start}}$ pro Schritt
- $2j$ Schritte bis alle PEs in **Schicht j** erreicht
- $d = \lceil \log(p+1) \rceil$ Schichten
- Dann **2** Schritte pro weitere **2** Pakete

$$T(n, p, k) \approx \left(\frac{n}{k}T_{\text{byte}} + T_{\text{start}} \right) (2d + k - 1), \text{ mit } d \approx \log p$$

optimales k : $\sqrt{\frac{n(2d-1)T_{\text{byte}}}{T_{\text{start}}}}$

$$T^*(n, p) \approx \textcolor{red}{n}T_{\text{byte}} + T_{\text{start}} \cdot 2 \log p + \sqrt{2n \log p T_{\text{start}} T_{\text{byte}}}$$

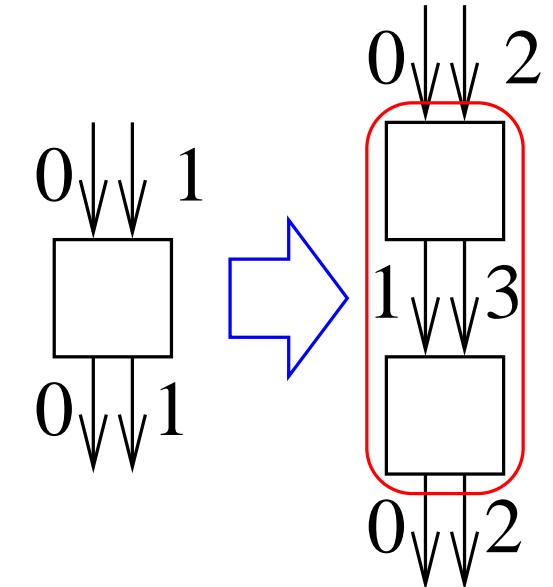




Implementierung im Simplex-Modell

2 Zeitschritt duplex \rightsquigarrow 4 Zeitschritt simplex.

1 PE duplex \rightsquigarrow 1 simplex couple = sender + receiver.



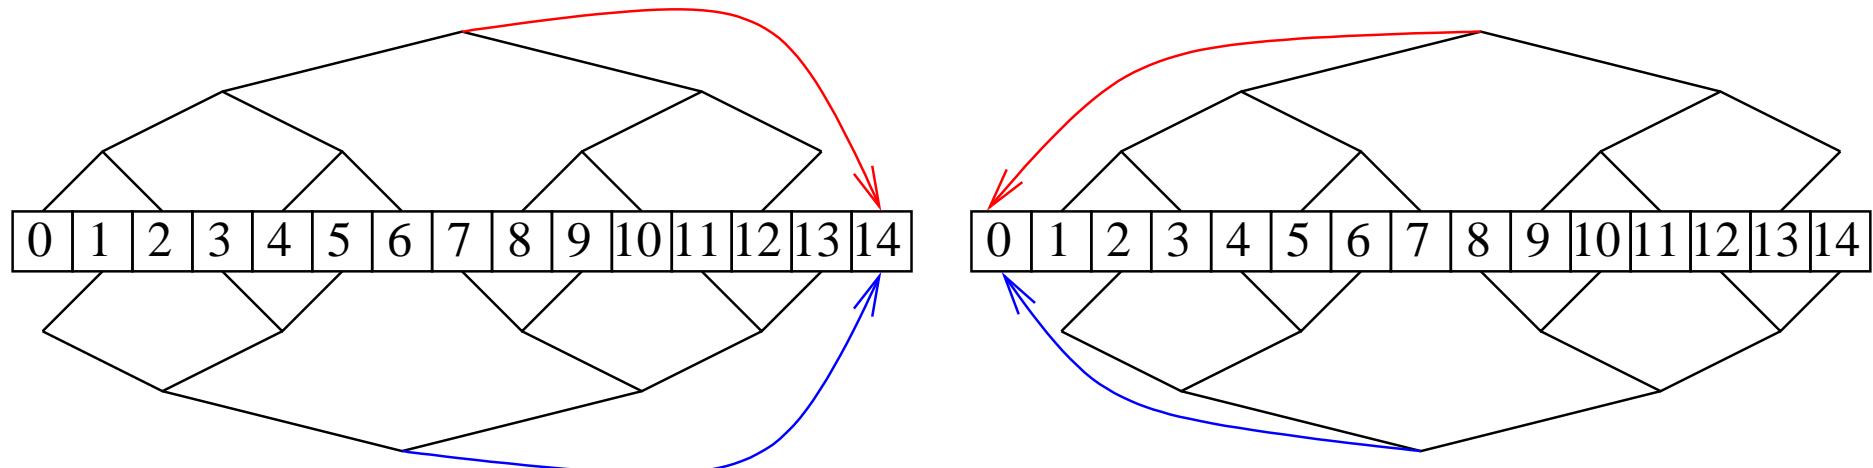
Offene Frage:

Direkte Implementierung im simplex-Modell ? \rightsquigarrow 4-Kantenfärbung eines Graphen mit max. Grad 4. Überhaupt möglich?

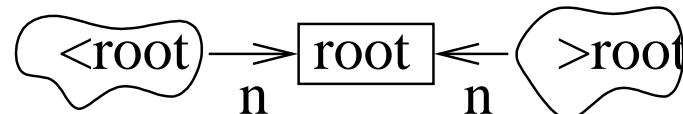
23-Reduktion

Nummerierung ist Inorder-Nummerierung für **beide** Bäume !

kommutativ oder $\text{root}=0$ oder $\text{root}=p-1$:



sonst:



Noch ein optimaler Algorithmus

[Johnsson Ho 85: Optimal Broadcasting and Personalized Communication in Hypercube, IEEE Transactions on Computers, vol. 38, no.9, pp. 1249-1268.]

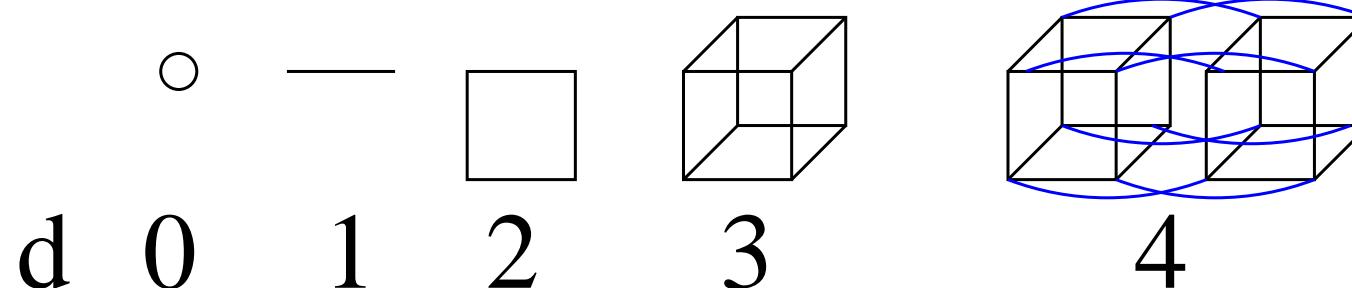
Idee: getrennt marschieren — vereint schlagen

Modell: voll-duplex eingeschränkt auf einzige Kante pro PE
(Telefonmodell)

Anpassung halb-duplex: alles $\times 2$

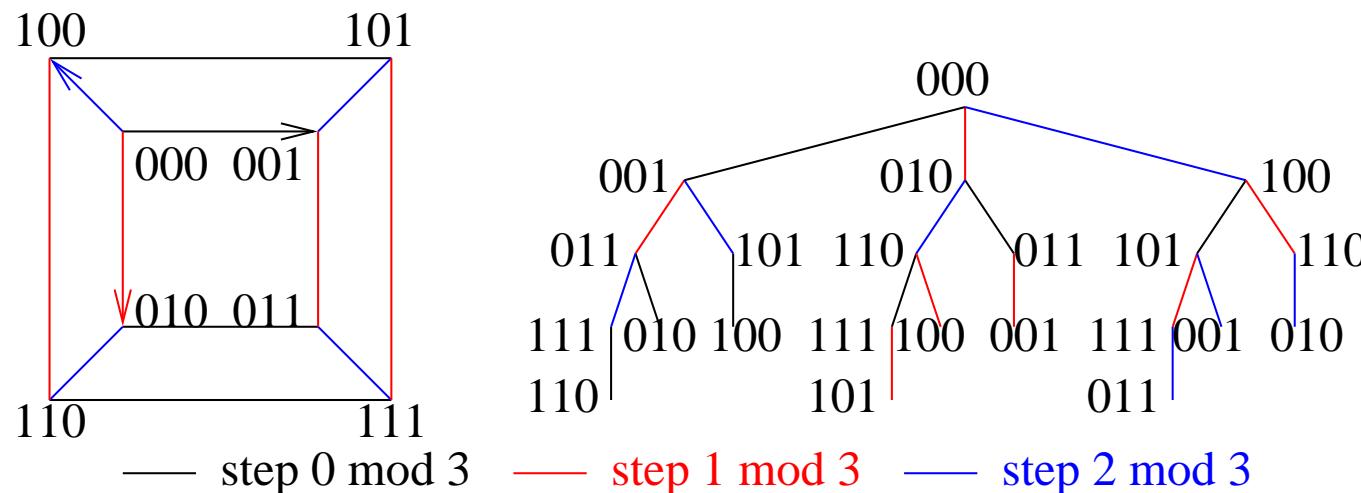
Hyperwürfel H_d

- $p = 2^d$ PEs
- Knoten $V = \{0, 1\}^d$, also Knotennummern binär aufschreiben
- Kanten in Dimension i : $E_i = \{(u, v) : u \oplus v = 2^i\}$
- $E = E_0 \cup \dots \cup E_{d-1}$



ESBT-Broadcasting

- In Schritt i Kommunikation entlang Dimension $i \bmod d$
- Zerlege H_d in d Edge-disjoint Spanning Binomial Trees
- 0^d verteilt zyklisch Pakete an Wurzeln der ESBTs
- ESBT-Wurzeln machen binomial tree broadcasting
(außer fehlender kleinster Unterbaum 0^d)



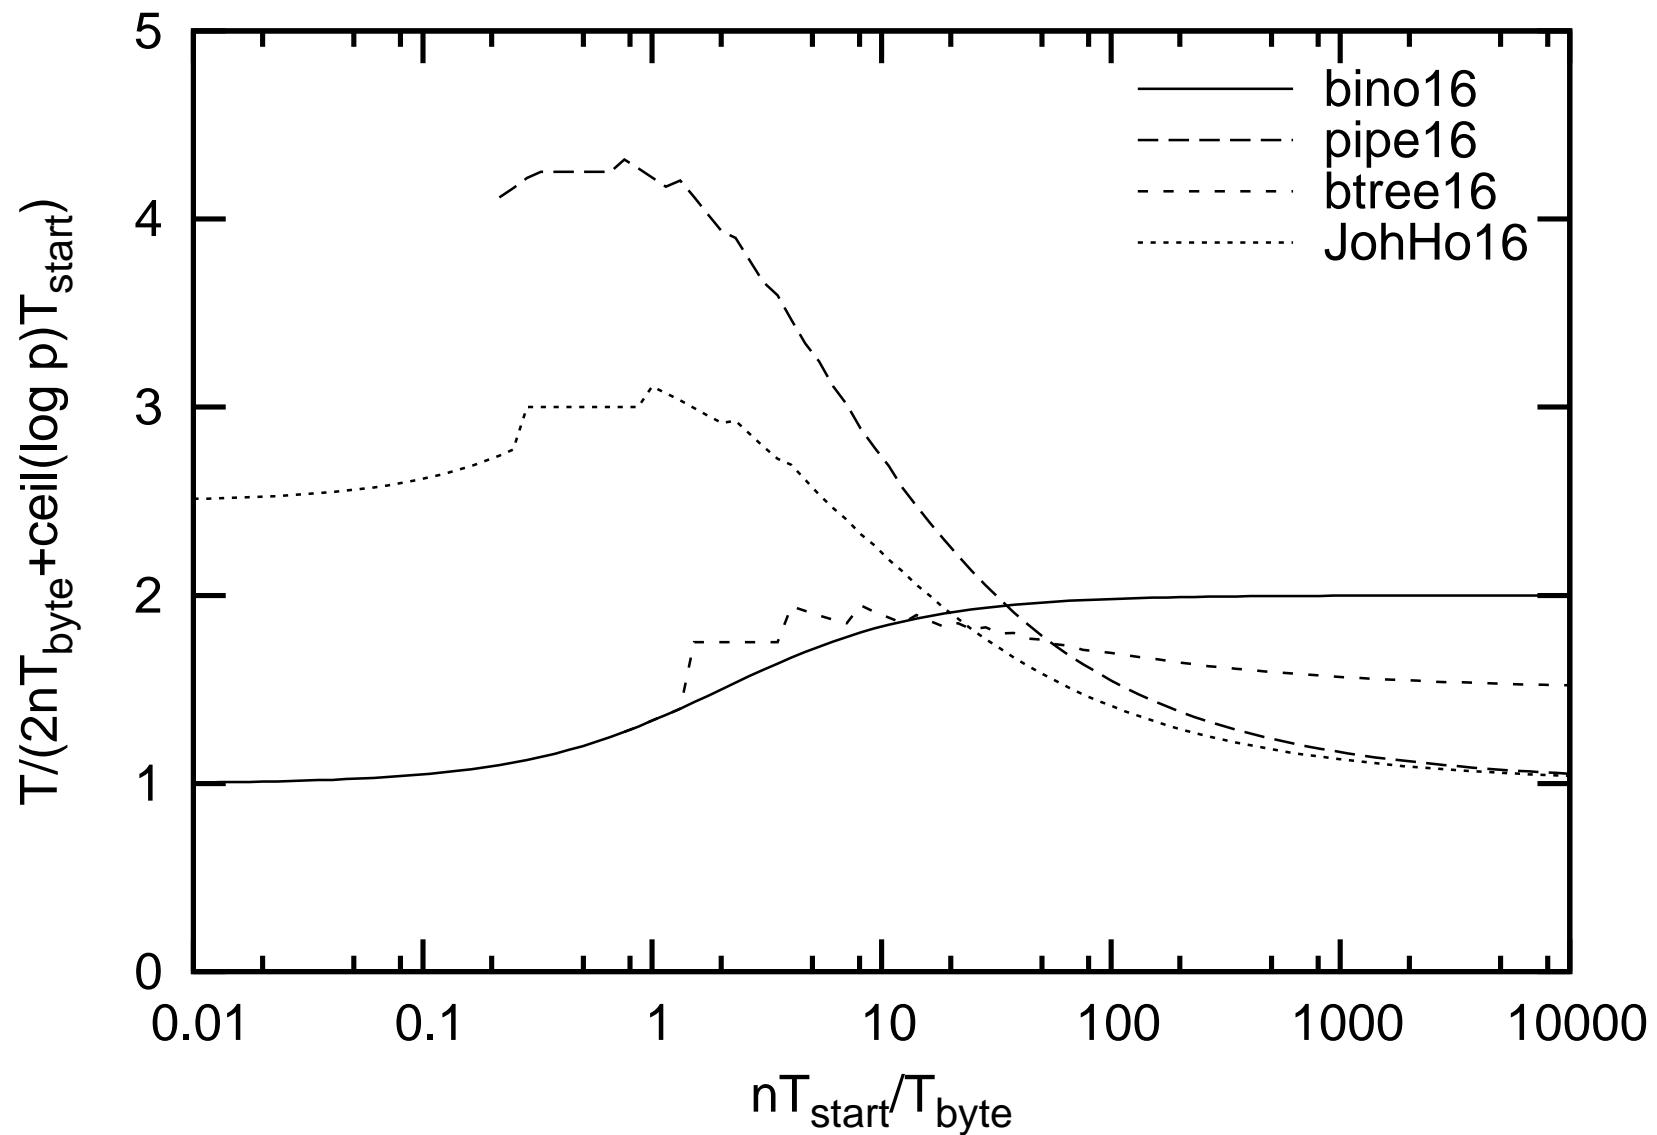
Analyse, Telefonmodell

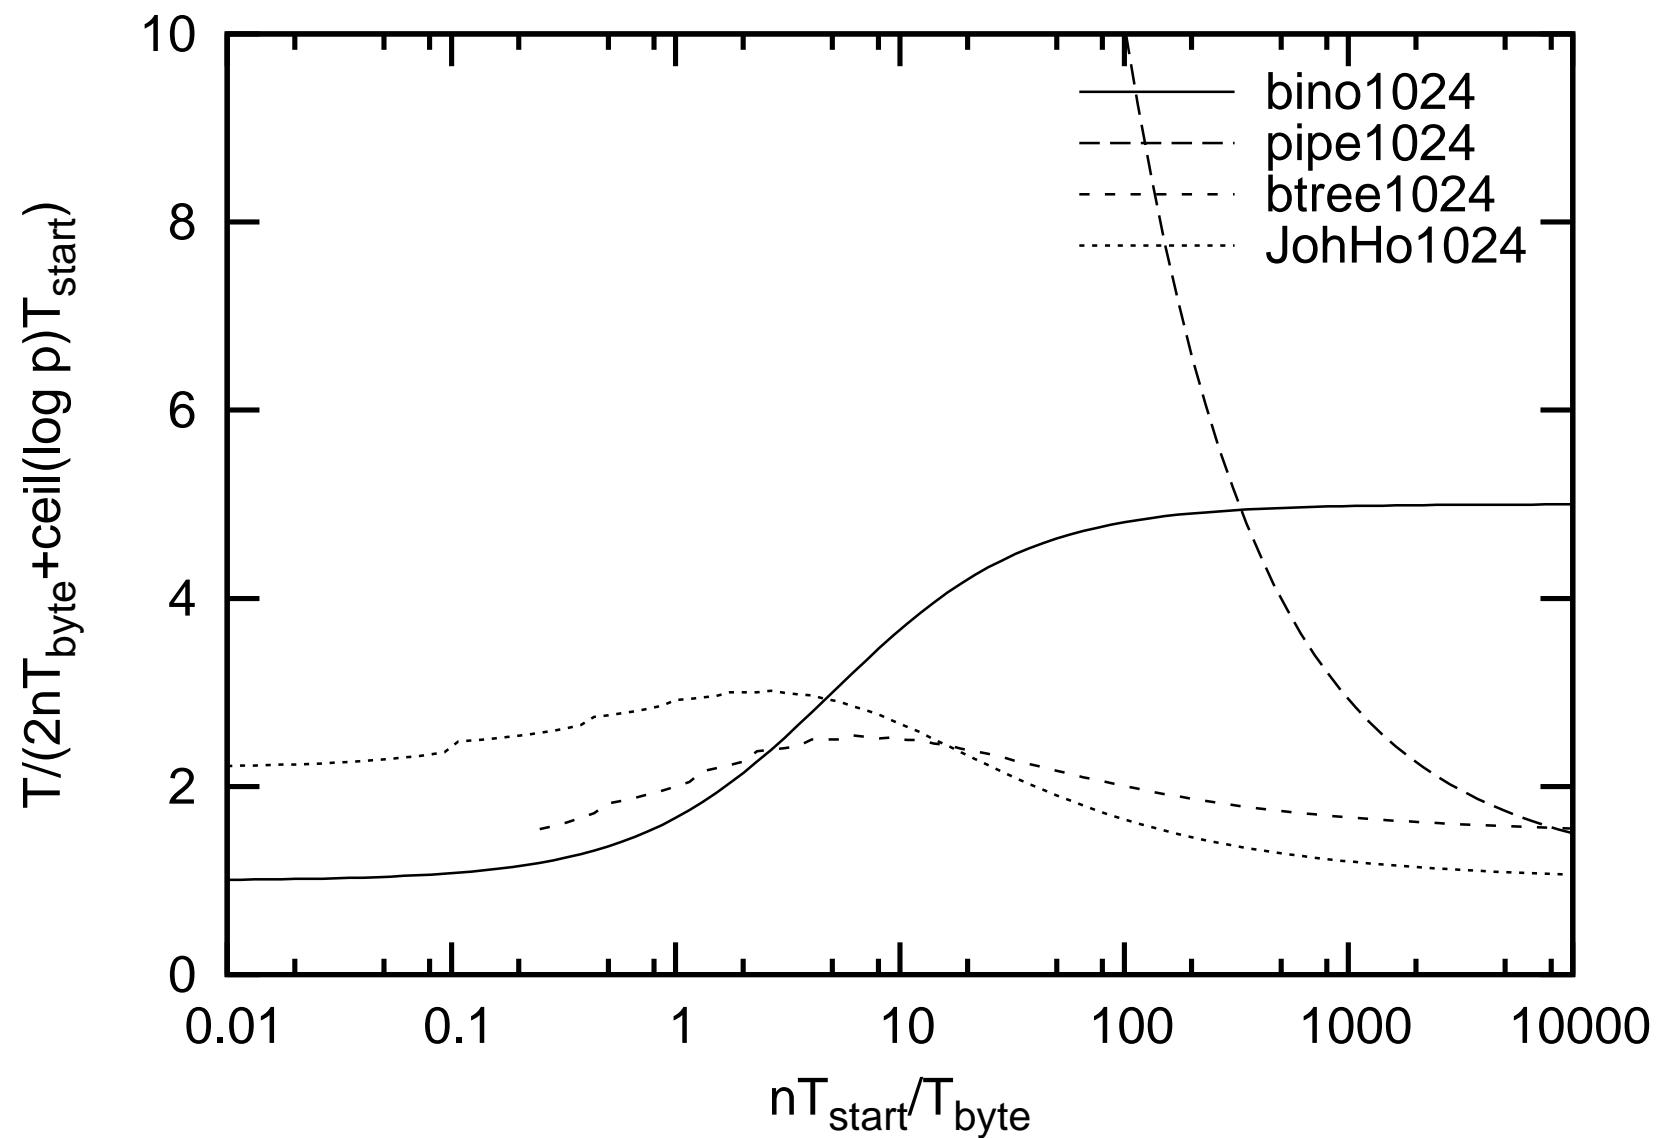
- k Pakete, k teilt n
- k Schritte bis letztes Paket PE 0 verlassen hat
- d Schritte bis es das letzte Blatt erreicht hat
- Insgesamt $d + k$ Schritte

$$T(n, p, k) = \left(\frac{n}{k} T_{\text{byte}} + T_{\text{start}} \right) (k + d)$$

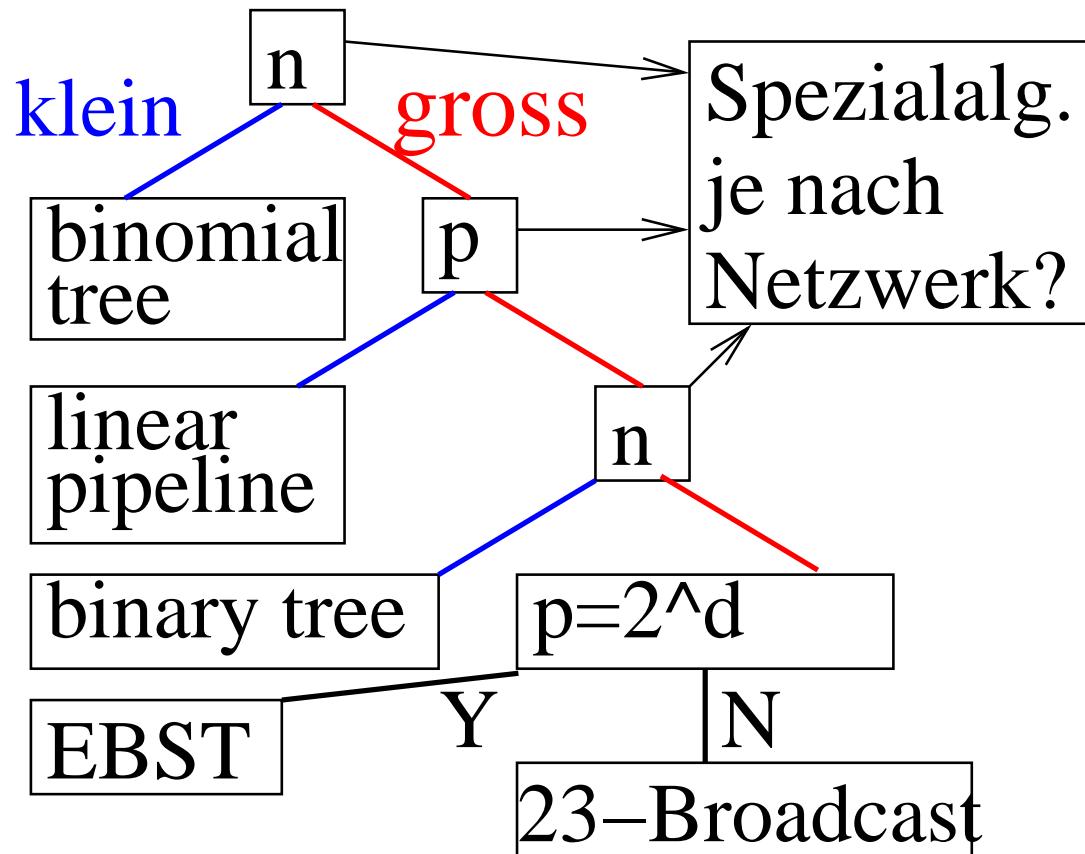
optimales k : $\sqrt{\frac{ndT_{\text{byte}}}{T_{\text{start}}}}$

$$T^*(n, p) := nT_{\text{byte}} + dT_{\text{start}} + \sqrt{ndT_{\text{start}}T_{\text{byte}}}$$





Diskussion



Reality Check

- Libraries (z.B. MPI) haben oft keine pipelined Implementierungen von kollektiven Operationen \rightsquigarrow eigener Broadcast **kann** deutlich schneller sein als Bibliotheksfunktion.
- k einstellen ist komplizierter: nur **abschnittweise lineare** Kostenfunktion für Punkt-zu-Punkt-Kommunikation, Rundung
- Fibonacci-Baum etc. bei asynchroner Kommunikation ggf. modifizieren (Sender ist eher fertig als Empfänger). Daten sollen an allen Blättern ungefähr gleichzeitig ankommen.

Broadcast für Bibliotheksimplementierer

- EINE** Implementierung? \rightsquigarrow 23-Broadcast
- Wenig, einfache Varianten? $\{$ binomial tree, 23-Broadcast $\}$ oder
 $\{$ binomial tree, 23-Broadcast, lineare Pipeline $\}$

Jenseits Broadcast

- Pipelining ist wichtige Technik zu Umgang mit großen Datenmengen.
- Hyperwürfelalgorithmen sind oft elegant und effizient. (Und oft einfacher als ESBT)
- Parametertuning (z.B. v. k) ist oft wichtig.

Sortieren

[Sanders Worsch Kapitel 6]

- Schnelles ineffizientes Ranking
- Quicksort
- Sample Sort
- Multiway Mergesort
- Selection
- Mehr zu Sortieren

Schnelles ineffizientes Ranking

m Elemente, m^2 Prozessoren:

Input: $A[1..m]$ // distinct elements

Output: $M[1..m]$ // $M[i] =$ rang von $A[i]$

forall $(i, j) \in \{1..n\}^2$ **dopar** $B[i, j]:= A[i] \geq A[j]$

forall $i \in \{1..n\}$ **dopar**

$M[i]:= \sum_{j=1}^n B[i, j]$ // parallel subroutine

Ausführungszeit: $\approx T_{\text{broadcast}}(1) + T_{\text{reduce}}(1) = \mathcal{O}(T_{\text{start}} \log p)$

i	A	B	1	2	3	4	5	<-	j	M
1	3		1	0	1	0	1			1
2	5		1	1	1	0	1			1
3	2		0	0	1	0	1			1
4	8		1	1	1	1	1			1
5	1		0	0	0	0	1			1
	A		3	5	2	8	1			

i	A	B	1	2	3	4	5	<-	j	M
1	3		1	0	1	0	1			3
2	5		1	1	1	0	1			4
3	2		0	0	1	0	1			2
4	8		1	1	1	1	1			5
5	1		0	0	0	0	1			1

Sortieren größerer Datenmengen

- $m = np$ Eingabewerte. Anfangs n pro PE
- u.U. allgemeiner
- Ausgabe global sortiert

$$\boxed{d_{0,0}, \dots, d_{0,n-1}} \quad , \dots, \quad \boxed{d_{p-1,0}, \dots, d_{p-1,n-1}}$$

 $\Downarrow \pi$

$$\boxed{s_{0,0} \leq \dots \leq s_{0,n_1-1}} \leq \dots \leq \boxed{s_{p-1,0} \leq \dots \leq s_{p-1,n_{p-1}-1}}$$

- Vergleichsbasiertes Modell
- $T_{\text{seq}} = T_{\text{compr}} m \log m + \mathcal{O}(m)$

Zurück zum schnellen Ranking

// Assume $p = a \times b$ PEs, PE Index is (i, j)

Procedure matrixRank(s)

 sort(s) // locally

$r :=$ all-gather-by-rows(s , merge)

$c :=$ all-gather-by-cols(s , merge)

 ranks:= $\langle |\{x \in c : y \leq x\}| : y \in r \rangle$ // merge

 reduce-by-rows(ranks)

Time

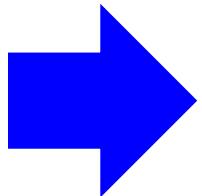
$$\mathcal{O}\left(T_{\text{start}} \log p + T_{\text{byte}} \frac{m}{\sqrt{p}} + \frac{m}{p} \log \frac{m}{p}\right) . \quad (1)$$

Beispiel

h	g	d	l
e	a	m	b
k	i	c	j

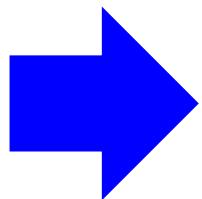
row all-gather-merge

h	g	d	l
e	a	m	b
k	i	c	j



dghl	dghl	dghl	dghl
abem	abem	abem	abem
ci jk	ci jk	ci jk	ci jk

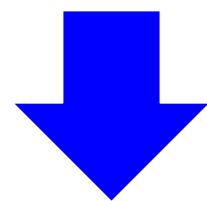
h	g	d	l
e	a	m	b
k	i	c	j



dghl	dghl	dghl	dghl
abem	abem	abem	abem
cijk	cijk	cijk	cijk

row all-gather-merge

col all-gather-merge



dghl	e	dghl	a	dghl	C	dghl	b
h			g		d		j
k			i		m		l

abem	e	abem	a	abem	C	abem	b
h			g		d		j
k			i		m		l

cijk	e	cijk	a	cijk	C	cijk	b
h			g		d		j
k			i		m		l

h	g	d	l
e	a	m	b
k	i	c	j

dghl 0123 _{h k}	dghl 1223 _{a g i}	dghl 2222 _{c d m}	dghl 1113 _{b j l}
abem 0013 _{e h k}	abem 1113 _{a g i}	abem 0023 _{c d m}	abem 0113 _{b j l}
cijk 0223 _{e h k}	cijk 1333 _{a g i}	cijk 1222 _{c d m}	cijk 1122 _{b j l}

h	g	d	l
e	a	m	b
k	i	c	j

dghl e 0123 h k	dghl a 1223 g i	dghl c 2222 d m	dghl b 1113 j l	d g h l 4 6 7 11
abem e 0013 h k	abem a 1113 g i	abem c 0023 d m	abem b 0113 j l	a b e m 1 2 5 12
cijk e 0223 h k	cijk a 1333 g i	cijk c 1222 d m	cijk b 1122 j l	c i j k 3 8 9 10

Genauere Analyse, n 10 byte elemente pro PE

local sorting: $n \log n T_{\text{compr}}$

2× all-gather: $2 \left(10n\sqrt{p}T_{\text{byte}} + \frac{1}{2} \log p T_{\text{start}} \right)$

local ranking: $2n\sqrt{p}T_{\text{compr}}$

reduce JoHo-Algorithm:

$$10n\sqrt{p}T_{\text{byte}} + \frac{1}{2} \log p T_{\text{start}} + \sqrt{10n\sqrt{p} \frac{1}{2} \log p T_{\text{start}} T_{\text{byte}}}$$

Overall:

$$\frac{3}{2} \log p T_{\text{start}} + 30n\sqrt{p}T_{\text{byte}} + \sqrt{5n\sqrt{p} \log p T_{\text{start}} T_{\text{byte}}} + n \log n T_{\text{compr}}$$

Rechenbeispiel:

$p = 1024, T_{\text{start}} = 10^{-5} \text{ s}, T_{\text{byte}} = 10^{-9} \text{ s}, T_{\text{compr}} = 10^{-8} \text{ s}$ 10 Byte elements, $n = 32$.

$$\frac{3}{2} \log p T_{\text{start}} + 30n \sqrt{p} T_{\text{byte}} + \sqrt{5n \sqrt{p} \log p T_{\text{start}} T_{\text{byte}}} + n \log n T_{\text{compr}}$$

Zeit $\approx 0.200 \text{ ms}$.

Zum Vergleich: effizienter Gather+seq. sort:

$$2 \cdot 32000 \cdot 10 \cdot 10^{-9} + 10 \cdot 10^{-5} + 32000 \cdot 15 \cdot 10^{-8} \approx 5.6 \text{ ms}$$

noch größerer Unterschied bei naivem gather

Quicksort

Sequentiell

Procedure qSort($d[]$, p')

if $p' = 1$ **then return**

select a **pivot** v

reorder the elements in d such that

$$d_0 \leq \dots \leq d_k = v \leq d_{k+1} \leq \dots \leq d_{p'-1}$$

qSort($[d_0, \dots, d_{k-1}]$, k)

qSort($[d_{k+1}, \dots, d_{p'-1}]$, $m - k - 1$)

Anfänger-Parallelisierung

Parallelisierung der rekursiven Aufrufe.

$$T_{\text{par}} = \Omega(m)$$

- Sehr begrenzter Speedup
- Schlecht für distributed Memory

Theoretiker-Parallelisierung

Zur Vereinfachung: $m = p$.

Idee: Auch die Aufteilung parallelisieren.

1. Ein PE stellt den Pivot (z.B. zufällig).
2. Broadcast
3. Lokaler Vergleich
4. „Kleine“ Elemente durchnummerieren (Präfix-Summe)
5. Daten umverteilen
6. Prozessoren aufspalten
7. Parallel Rekursion

Theoretiker-Parallelisierung

//Let $i \in 0..p - 1$ and p denote the ‘local’ PE index and partition size

Procedure theoQSort(d, i, p)

if $p = 1$ **then return**

$j :=$ random element from $0..p - 1$ // same value in entire partition

$v := d @ j$ // broadcast pivot

$f := d \leq v$

$j := \sum_{k=0}^i f @ k$ // prefix sum

$p' := j @ (p - 1)$ // broadcast

if f **then** send d to PE j

else send d to PE $p' + i - j$ // $i - j = \sum_{k=0}^i d @ k > v$

receive d

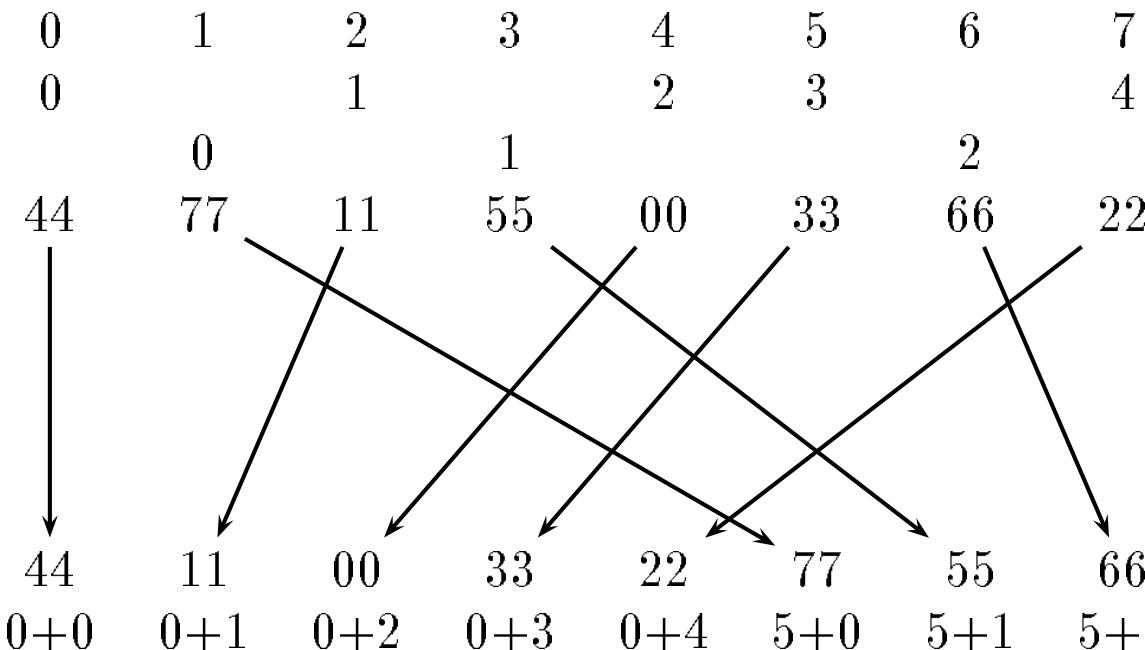
if $i < p'$ **then** join left partition; qsort(d, i, p')

else join right partition; qsort($d, i - p', p - p'$)

Beispiel

pivot $v = 44$

PE Nummer	0	1	2	3	4	5	6	7
Nr. d. Elemente \leq Pivot	0	1			2	3		4
Nr. d. Elemente $>$ Pivot		0	1			2		
Wert vorher	44	77	11	55	00	33	66	22
Wert nachher	44	11	00	33	22	77	55	66
PE Nummer	0+0	0+1	0+2	0+3	0+4	5+0	5+1	5+2



```

graph TD
    P0[44] --> P0_0[44]
    P1[77] --> P0_1[11]
    P2[11] --> P0_2[00]
    P3[55] --> P0_3[33]
    P4[00] --> P0_4[22]
    P5[33] --> P1_0[77]
    P6[66] --> P1_1[55]
    P7[22] --> P1_2[66]
    P0_0[44] --> P1_0[77]
    P0_1[11] --> P1_1[55]
    P0_2[00] --> P1_2[66]
    P0_3[33] --> P2_0[00]
    P0_4[22] --> P2_1[33]
    P0_5[77] --> P3_0[22]
    P0_6[55] --> P3_1[77]
    P0_7[66] --> P4_0[55]
    P1_0[77] --> P2_0[00]
    P1_1[55] --> P2_1[33]
    P1_2[66] --> P3_0[22]
    P2_0[00] --> P3_0[22]
    P2_1[33] --> P3_1[77]
    P3_0[22] --> P4_0[55]
    P3_1[77] --> P4_1[66]
  
```

```
int pQuickSort(int item, MPI_Comm comm)
{ int iP, nP, small, allSmall, pivot;
  MPI_Comm newComm; MPI_Status status;
  MPI_Comm_rank(comm, &iP); MPI_Comm_size(comm, &nP);

  if (nP == 1) { return item; }
  else {
    pivot = getPivot(item, comm, nP);
    count(item < pivot, &small, &allSmall, comm, nP);
    if (item < pivot) {
      MPI_Bsend(&item, 1, MPI_INT, small - 1, 8, comm);
    } else {
      MPI_Bsend(&item, 1, MPI_INT, allSmall+iP-small, 8, comm);
    }
    MPI_Recv(&item, 1, MPI_INT, MPI_ANY_SOURCE, 8, comm, &status);
    MPI_Comm_split(comm, iP < allSmall, 0, &newComm);
    return pQuickSort(item, newComm); } }
```

```
/* determine a pivot */

int getPivot(int item, MPI_Comm comm, int nP)
{ int pivot = item;
  int pivotPE = globalRandInt(nP); /* from random PE */
  /* overwrite pivot by that one from pivotPE */
  MPI_Bcast(&pivot, 1, MPI_INT, pivotPE, comm);
  return pivot;
}

/* determine prefix-sum and overall sum over value */
void
count(int value,int *sum,int *allSum,MPI_Comm comm,int nP)
{ MPI_Scan(&value, sum, 1, MPI_INT, MPI_SUM, comm);
  *allSum = *sum;
  MPI_Bcast(allSum, 1, MPI_INT, nP - 1, comm);
}
```

Analyse

- pro Rekursionsebene:
 - $2 \times$ broadcast
 - $1 \times$ Präfixsumme (\rightarrow später)
 - \rightsquigarrow Zeit $\mathcal{O}(T_{\text{start}} \log p)$
- erwartete Rekursionstiefe: $\mathcal{O}(\log p)$
 $(\rightarrow$ Vorlesung randomisierte Algorithmen $)$

Erwartete Gesamtzeit: $\mathcal{O}(T_{\text{start}} \log^2 p)$

Verallgemeinerung für $m \gg p$ nach Schema F?

- Jedes PE hat i.allg. „große“ und „kleine“ Elemente.
- Aufteilung geht nicht genau auf
- Präfixsummen weiterhin nützlich
- Auf PRAM ergibt sich ein $\mathcal{O}\left(\frac{m \log m}{p} + \log^2 p\right)$ Algorithmus
- Bei verteiltem Speicher stört, dass jedes Element $\Omega(\log p)$ mal transportiert wird.
 $\rightsquigarrow \dots \rightsquigarrow$ Zeit $\mathcal{O}\left(\frac{m}{p}(\log n + T_{\text{byte}} \log p) + T_{\text{start}} \log^2 p\right)$

Distributed memory parallel quicksort

Function parQuickSort(s : Sequence of Element, $i, j : \mathbb{N}$) : Sequence of Element

$$p' := j - i + 1$$

if $p' = 1$ **then** quickSort(s) ; **return** s // sort locally

$$v := \text{pickPivot}(s, i, j)$$

$$a := \langle e \in s : e \leq v \rangle; \quad b := \langle e \in s : e > v \rangle$$

$$n_a := \sum_{i \leq k \leq j} |a| @ k; \quad n_b := \sum_{i \leq k \leq j} |b| @ k$$

$$k' := \frac{n_a}{n_a + n_b} p'$$

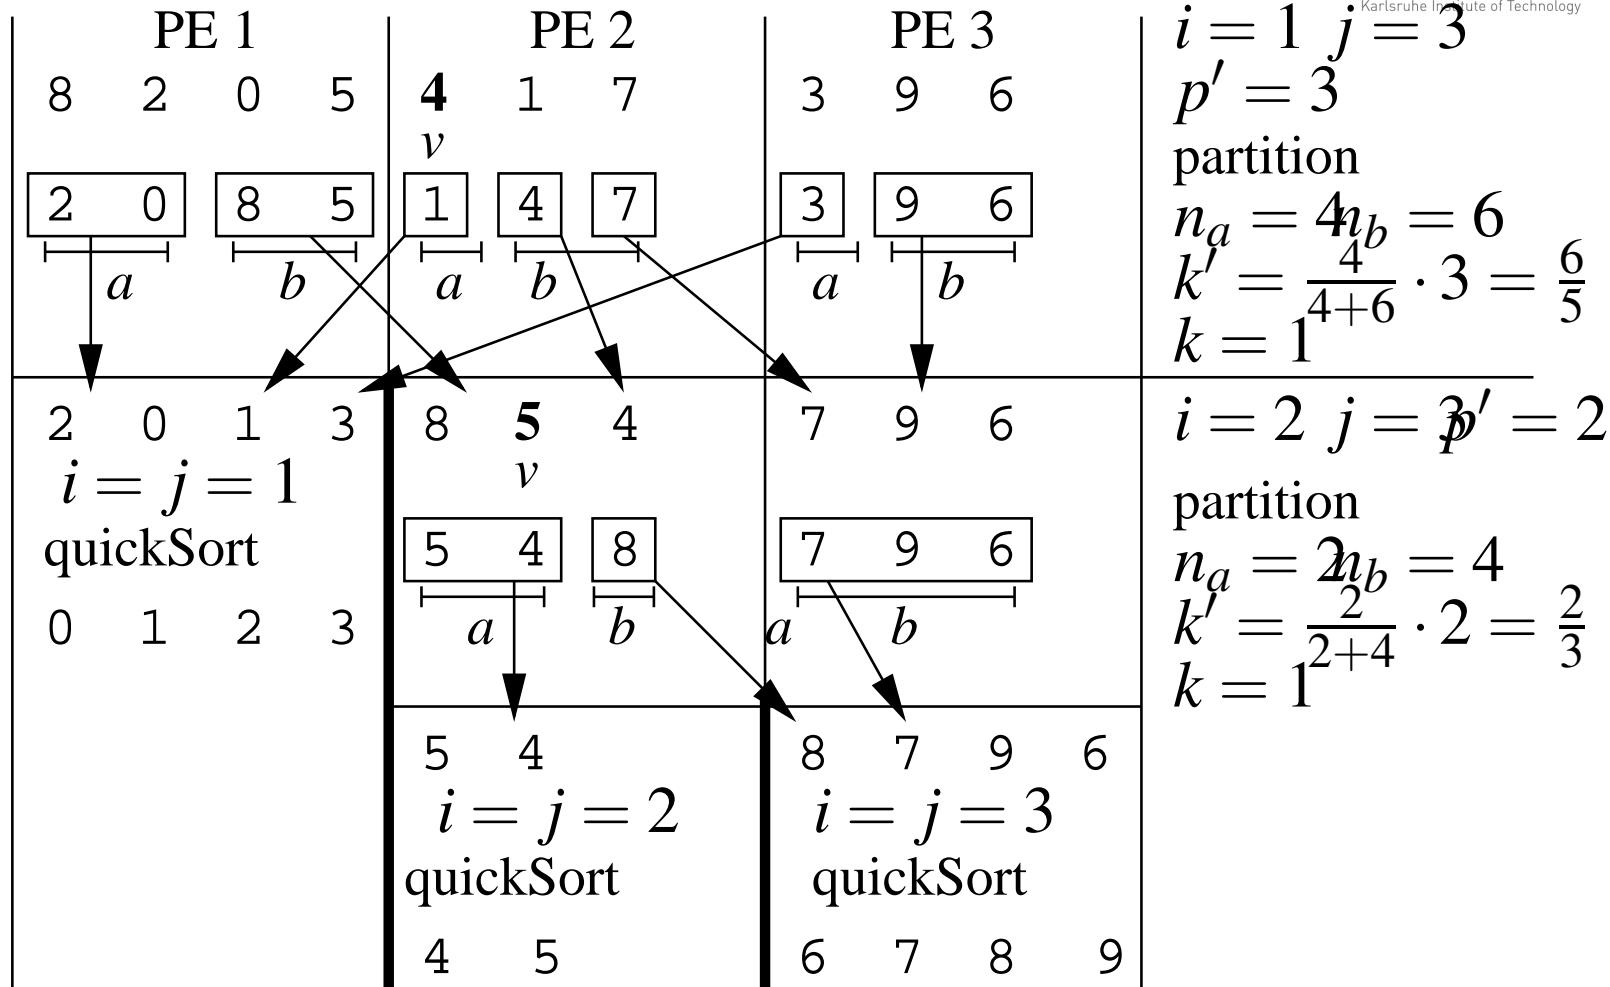
choose $k \in \{\lfloor k' \rfloor, \lceil k' \rceil\}$ such that $\max \left\{ \lceil \frac{n_a}{k} \rceil, \lceil \frac{n_b}{p' - k} \rceil \right\}$ is minimized

send the a -s to PEs $i..i+k-1$ ($\leq \lceil \frac{n_a}{k} \rceil$ per PE)

send the b -s to PEs $i+k..j$ ($\leq \lceil \frac{n_b}{p'-k} \rceil$ per PE)

receive data sent to PE i_{PE} into s

if $i_{\text{PE}} < i+k$ **then** parQuickSort($s, i, i+k-1$) **else** parQuickSort($s, i+k, j$)



Load Balance

Veieinfachtes Szenario: Splitting immer im Verhältnis 1:2

größeres Teilproblem kriegt ein PE-Load zu viel.

Imbalance-Faktor:

$$\begin{aligned} \prod_{i=1}^k 1 + \frac{1}{p\left(\frac{2}{3}\right)^i} &= e^{\sum_{i=1}^k \ln\left(1 + \frac{1}{p\left(\frac{2}{3}\right)^i}\right)} \\ &\leq e^{\sum_{i=1}^k \frac{1}{p\left(\frac{2}{3}\right)^i}} = e^{\frac{1}{p} \sum_{i=0}^k \left(\frac{3}{2}\right)^i} \text{ geom. Summe} \\ &= e^{\frac{1}{p} \frac{\left(\frac{3}{2}\right)^{k+1} - 1}{\frac{3}{2} - 1}} \leq e^{\frac{1}{p} 3 \left(\frac{3}{2}\right)^k} = e^3 \approx 20.1 . \end{aligned}$$

Die gute Nachricht:

Zeit $\mathcal{O}\left(\frac{m}{p} \log m + \log^2 p\right)$

Bessere Lastbalancierung?

- schizophrenic quicksort?
- bei kleinem p' pivot sorgfältig wählen
- bei kleinem p' ($\Theta(\log p)$) auf sample sort umsteigen?

Multi-Pivot Verfahren

Vereinfachende Annahme: Splitter fallen vom Himmel

```
//Für  $0 < k < p$  sei  $v_k$  das Element mit Rang  $k \cdot m/p$ 
//Außerdem setzen wir  $v_0 = -\infty$  und  $v_p = \infty$ .
initialisiere  $P$  leere Nachrichten  $N_k$ , ( $0 \leq k < P$ )
for  $i := 0$  to  $n - 1$  do
    bestimme  $k$ , so daß  $v_k < d_i \leq v_{k+1}$ 
    nimm  $d_i$  in Nachricht  $N_k$  auf
    schicke  $N_i$  an PE  $i$  und                                // All-to-all
    empfange  $p$  Nachrichten                         // personalized communication
    sortiere empfangene Daten
```

Analyse

$$\begin{aligned} T_{\text{par}} &= \overbrace{\mathcal{O}(n \log p)}^{\text{verteilen}} + \overbrace{T_{\text{seq}}(n)}^{\text{lokal sortieren}} + \overbrace{T_{\text{all-to-all}}(p, n)}^{\text{Datenaustausch}} \\ &\approx \frac{T_{\text{seq}}(np)}{p} + 2nT_{\text{byte}} + pT_{\text{start}} \end{aligned}$$

Idealisierende Annahme ist realistisch für **Permutation**.

Sample Sort

choose a total of Sp random elements s_k , (S per PE) ($1 \leq k \leq Sp$)

```
sort [ $s_1, \dots, s_{Sp}$ ] // or only  
for  $i := 1$  to  $p - 1$  do  $v_i := s_{Si}$  // multiple selection  
 $v_0 := -\infty$ ;  $v_p := \infty$ 
```

unsortierte
Eingangsdaten

19	7	12
1	9	13
25	4	2

6	30	17
13	10	11
16	27	22

3	20	14
18	5	16
15	21	8

zufälliges
Sample

7 13 25

6 17 10

20 18 21

Sample sortiert
und aufgeteilt

6 7 10 | 13 17 18 | 20 21 25

Broadcast der
Pivotelemente

$(p_0 = -\infty)$ $p_1 = 10$ $p_2 = 18$ $(p_3 = \infty)$

Elemente
klassifiziert

I_0	I_1	I_2
1	12	25
4	13	19
2		
7		
9		

I_0	I_1	I_2
6	17	30
10	13	27
	11	22
	16	

I_0	I_1	I_2
3	14	20
5	18	21
8	16	
	15	

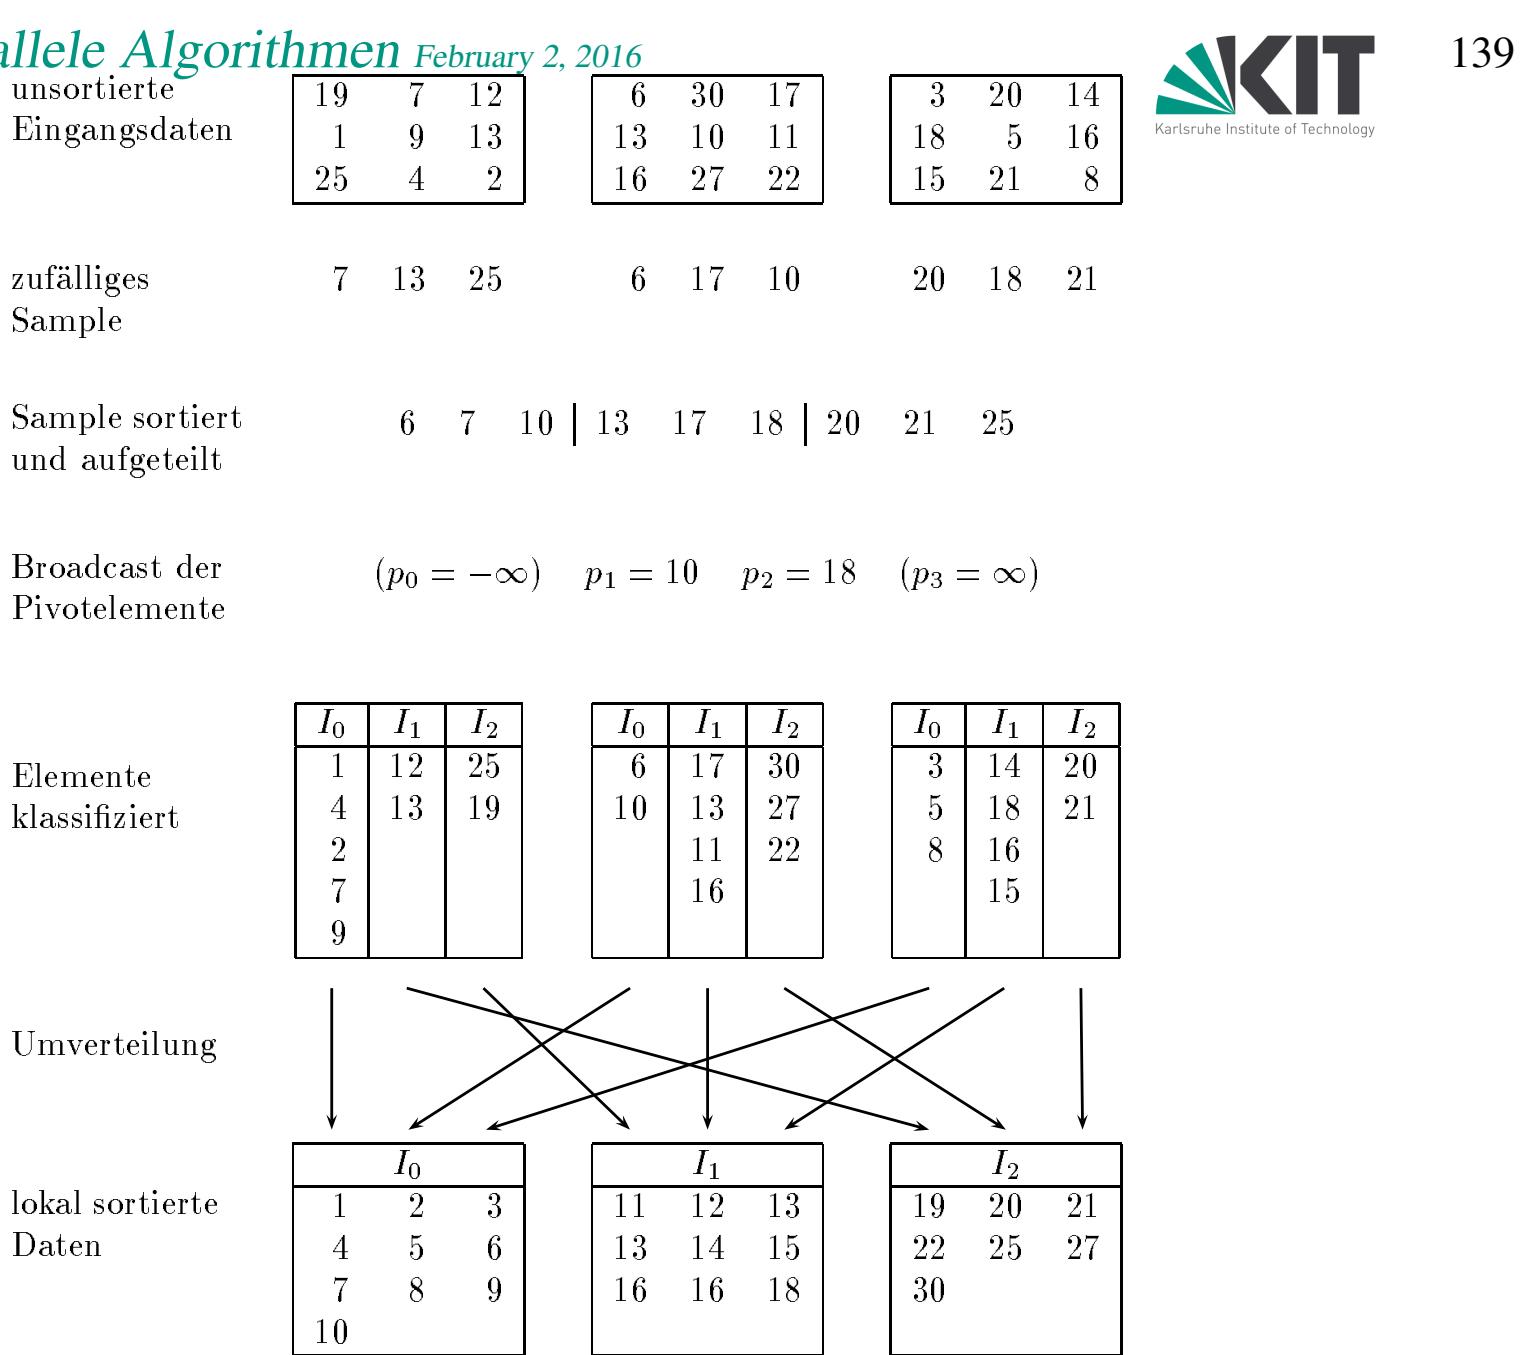
Umverteilung

lokal sortierte
Daten

I_0
1
2
3
4
5
6
7
8
9
10

I_1
11
12
13
14
15
16
16
18

I_2
19
20
21
22
25
27
30



Lemma 2. $S = \mathcal{O}\left(\frac{\log m}{\varepsilon^2}\right)$ genügt damit mit Wahrscheinlichkeit $\geq 1 - \frac{1}{m}$ kein PE mehr als $(1 + \varepsilon)n$ Elemente erhält.

Lemma:

$S = \mathcal{O}\left(\frac{\log m}{\varepsilon^2}\right)$ genügt damit mit Wahrscheinlichkeit $\geq 1 - \frac{1}{m}$ kein PE mehr als $(1 + \varepsilon)n$ Elemente erhält. Beweisansatz:

Wir analysieren einen Alg. bei dem global samples mit Zurücklegen gewählt werden.

Sei $\langle e_1, \dots, e_m \rangle$ die Eingabe in **sortierter Reihenfolge**.

fail: Ein PE kriegt mehr als $(1 + \varepsilon)n$ Elemente

$\rightarrow \exists j : \leq S$ samples aus $\langle e_j, \dots, e_{j+(1+\varepsilon)n} \rangle$ (Ereignis \mathcal{E}_j)

$\rightarrow \mathbb{P}[\text{fail}] \leq m\mathbb{P}[\mathcal{E}_j], j \text{ fest.}$

Sei $X_i := \begin{cases} 1 & \text{falls } s_i \in \langle e_j, \dots, e_{j+(1+\varepsilon)n} \rangle \\ 0 & \text{sonst} \end{cases}, X := \sum_i X_i$

$\mathbb{P}[\mathcal{E}_j] = \mathbb{P}[X < S] = \mathbb{P}[X < 1/(1 + \varepsilon)\mathbb{E}[X]] \approx \mathbb{P}[X < (1 - \varepsilon)\mathbb{E}[X]]$

$\mathbb{E}[X_i] = \mathbb{P}[X_i = 1] = \frac{1+\varepsilon}{p}$

Chernoff-Schranke

Lemma 3. Sei $X = \sum_i X_i$ die Summe unabhängiger 0-1 Zufallsvariablen.

$$\mathbb{P}[X < (1 - \varepsilon)\mathbb{E}[X]] \leq \exp\left(-\frac{\varepsilon^2 \mathbb{E}[X]}{2}\right).$$

Angewandt auf unser Problem:

$$\mathbb{P}[X < S] \leq \exp\left(-\frac{\varepsilon^2 S}{2}\right) \stackrel{!}{\leq} \frac{1}{m^2}$$

$$\leftrightarrow S \geq \frac{4}{\varepsilon^2} \ln m$$

■

Analyse von Sample Sort

$$T_{\text{sampleSort}}(p, n) = \underbrace{T_{\text{fastsort}}(p, \mathcal{O}\left(\frac{\log m}{\varepsilon^2}\right))}_{\substack{\text{sample sortieren} \\ \text{vertreiben}}} + \underbrace{T_{\text{allgather}}(p)}_{\substack{\text{splitter sammeln/verteilen} \\ \text{lokal sortieren}}} + \underbrace{\mathcal{O}(n \log p) + T_{\text{seq}}((1 + \varepsilon)n) + T_{\text{all-to-all}}(p, (1 + \varepsilon)n)}_{\text{Datenaustausch}}$$

klein wenn $n \gg p \log p$

Samples Sortieren

- Mit Gather/Gossiping
- Schnelles Ranking
- Paralleles Quicksort
- Rekursiv mit Sample-Sort

Mehrwegemischen

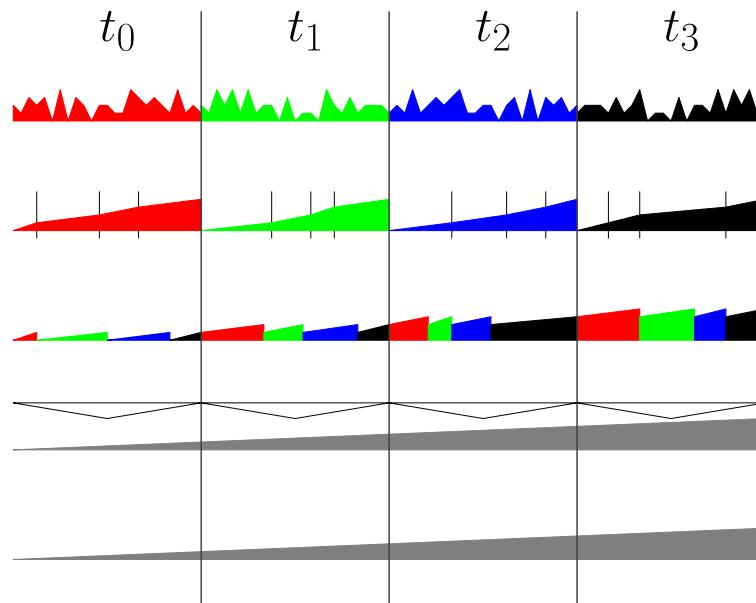
sort locally

v_k := the element with rank $k \cdot m/p$ // multisequence selection

forall $k \in 1..p$ **do**

send $\langle d_j : v_k \leq d_j < v_{k+1} \rangle$ to PE k // All-to-all

merge received data // p -way merging



Multisequence Selection

Idee: jedes PE bestimmt einen Splitter mit geeignetem globalem Rang
(shared memory)

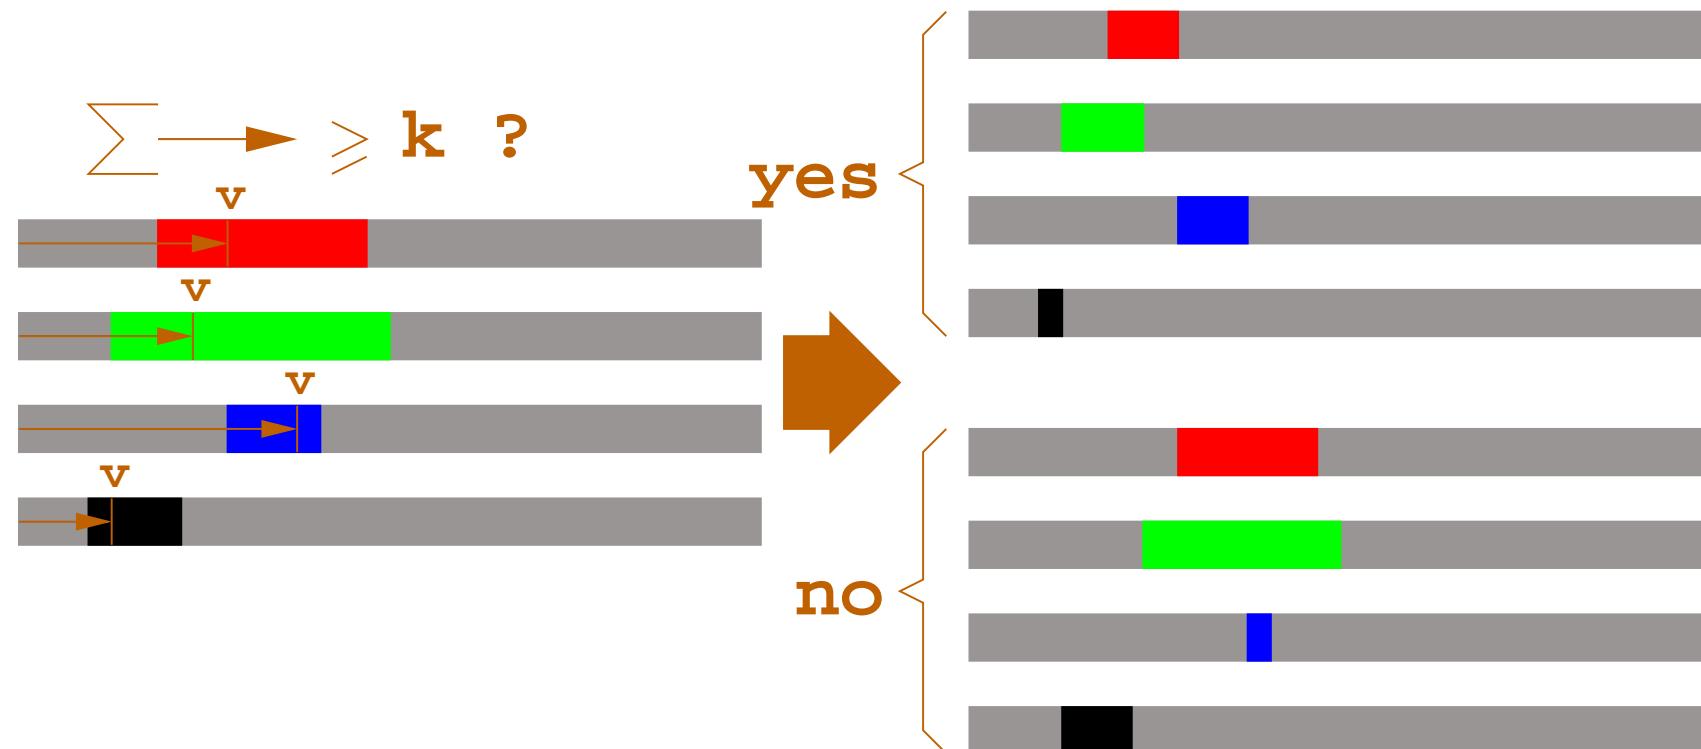
Vergleichsbasierte **untere Schranke**: $\mathcal{O}\left(p \log \frac{m}{p}\right)$

Wir geben Algorithmus mit $\mathcal{O}\left(p \log m \log \frac{m}{p}\right)$

Splitter Selection

Processor i selects the element with **global rank** $k = \frac{im}{p}$.

Simple algorithm: **quickSelect** exploiting sortedness of the sequences.



Idee:

Normales select aber $p \times$ binäre Suche statt Partitionierung

Function msSelect($S : \text{Array of Sequence of Element}; k : \mathbb{N}$) : $\text{Array of } \mathbb{N}$

for $i := 1$ **to** $|S|$ **do** $(\ell_i, r_i) := (0, |S_i|)$

invariant $\forall i : \ell_i..r_i$ contains the splitting position of S_i

invariant $\forall i, j : \forall a \leq \ell_i, b > r_j : S_i[a] \leq S_j[b]$

while $\exists i : \ell_i < r_i$ **do**

$v := \text{pickPivot}(S, \ell, r)$

for $i := 1$ **to** $|S|$ **do** $m_i := \text{binarySearch}(v, S_i[\ell_i..r_i])$

if $\sum_i m_i \geq k$ **then** $r := m$ **else** $\ell := m$

return ℓ

Verteilte Multisequence Selection

$\mathcal{O}(\log m)$ globale Rekursionslevel.

Gather + Broadcast für Pivotbestimmung/Verteilung (Vektorenlänge $p - 1$).

überall $p - 1$ lokale Suchen.

Reduktion für Bestimmung der Partitionsgrößen (Vektorenlänge $p - 1$).

Erwartete Zeit

$$\mathcal{O}\left(\log m \left(p\left(\log \frac{m}{p} + T_{\text{byte}}\right) + \log p T_{\text{start}}\right)\right)$$

Verteilte Multisequence Selection

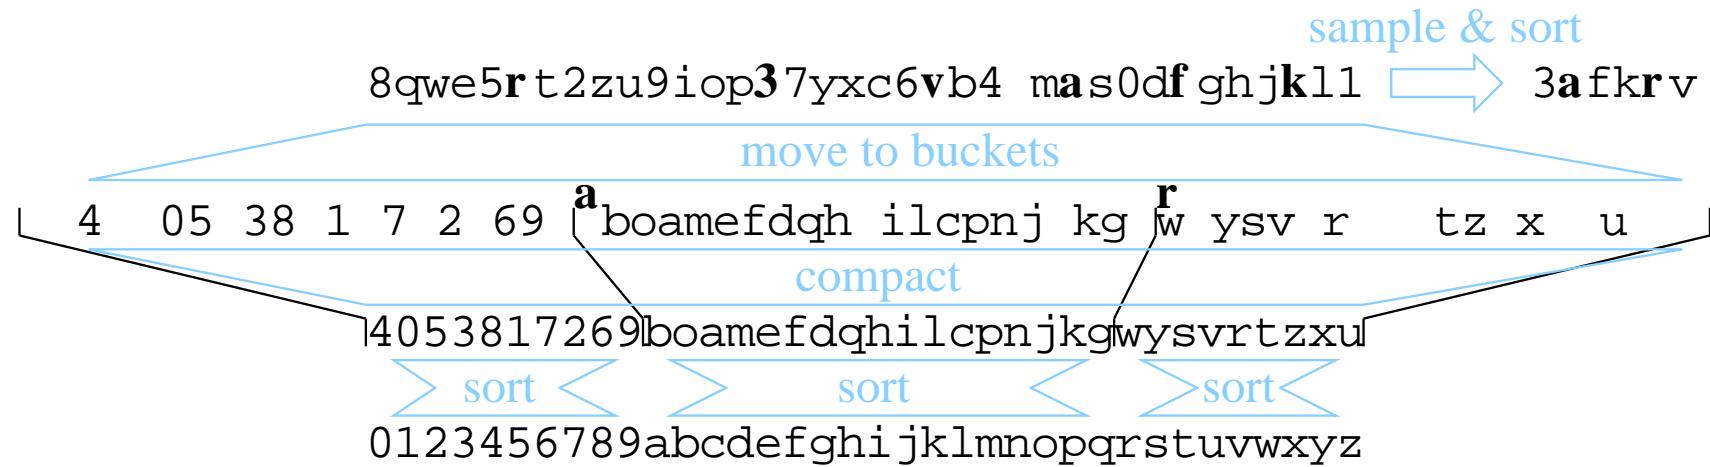
```
Function dmSelect(s : Seq of Elem; k : Array[1..p] of N) : Array[1..p] of N
    l, r, m, v, σ : Array [1..p] of N
    for i := 1 to p do (li, ri) := (0, |s|)      // initial search ranges
    while ∃i, j : li@j ≠ ri@j do                  // or-reduction
        v := pickPivotVector(s, l, r) // reduction, prefix sum, broadcast
        for i := 1 to p do mi := binarySearch(vi, s[li..ri])
        σ := ∑i mi@i                                // vector valued reduction
        for i := 1 to p do if σi ≥ ki then ri := mi else li := mi
    return l
```

CRCW Sortieren in logarithmischer Zeit

Sei $m = p$.

- sample der Größe \sqrt{p}
- $k = \Theta(\sqrt{p}/\log p)$ splitter
- Buckets haben Größe $\leq cp/k$ Elements mhW
- Alloziere Buckets der Größe $2cp/k$
- Schreibe Elemente an zufällig frei Position in ihrem Bucket
- Kompaktiere mittels Präfixsummen
- Rekursion

Beispiel



Mehr zu Sortieren

Cole's merge sort: [JáJá Section 4.3.2]

Zeit $\mathcal{O}\left(\frac{n}{p} + \log p\right)$ deterministisch, EREW PRAM (CREW in [JáJá]). Idee: Pipelined parallel merge sort. Nutze (deterministisches) sampling zur Vorhersage wo die Daten herkommen.

Sorting Networks: Knoten sortieren 2 Elemente. Einfache Netzwerke $\mathcal{O}(\log^2 n)$ (z.B. bitonic sort) ergeben brauchbare deterministische Sortieralgorithmen (2 Elemente \rightsquigarrow merge-and-split zweier sortierter Folgen). Sehr komplizierte mit Tiefe $\mathcal{O}(\log n)$.

Integer Sorting: (Annähernd) lineare Arbeit. Sehr schnelle Algorithmen auf CRCW PRAM.

Programmieraufgabe

Implementieren Sie einen parallelen Sortieralgorithmus.

Kombinationen aus $A \times B$ mit.

A: binary mergesort, multiway mergesort, hypercube quicksort,
quicksort + sample-sort, schizophrenic quicksort, fast inefficient
sort, CRCW logarithmic, sample-sort, Batcher sort, radix sort

B: MPI, C++11, Java, TBB, Cilk, OpenMP, CUDA, OpenCL, ...

Vergleichen Sie codes auf vergleichbaren Plattformen.

Separates Projekt: Vergleich mit existierenden parallelen Sortierern
(TBB, stdlib,...).

Kollektive Kommunikation

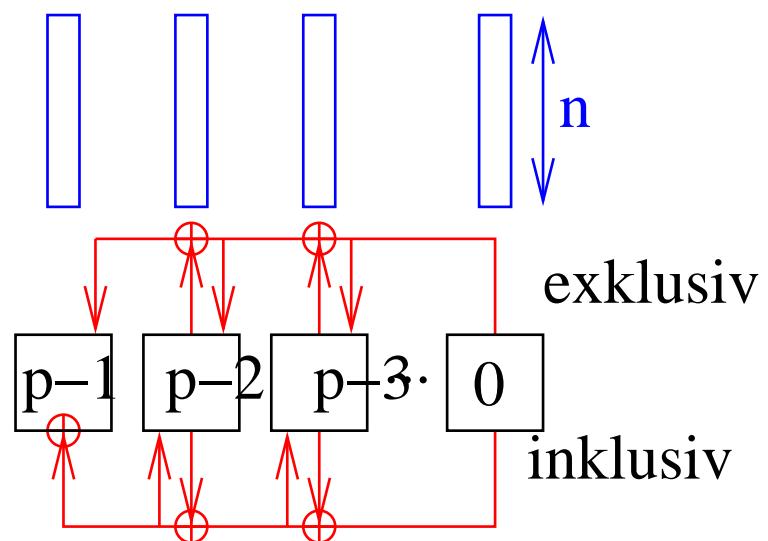
- Broadcast
- Reduktion
- Präfixsummen
- nicht hier: Sammeln / Austeilen (Gather / Scatter)
- Gossiping (= All-Gather = Gather + Broadcast)
- All-to-all Personalized Communication
 - gleiche Nachrichtenlängen
 - ungleiche Nachrichtenlängen, = *h*-Relation

Präfixsummen

[Leighton 1.2.2] Gesucht

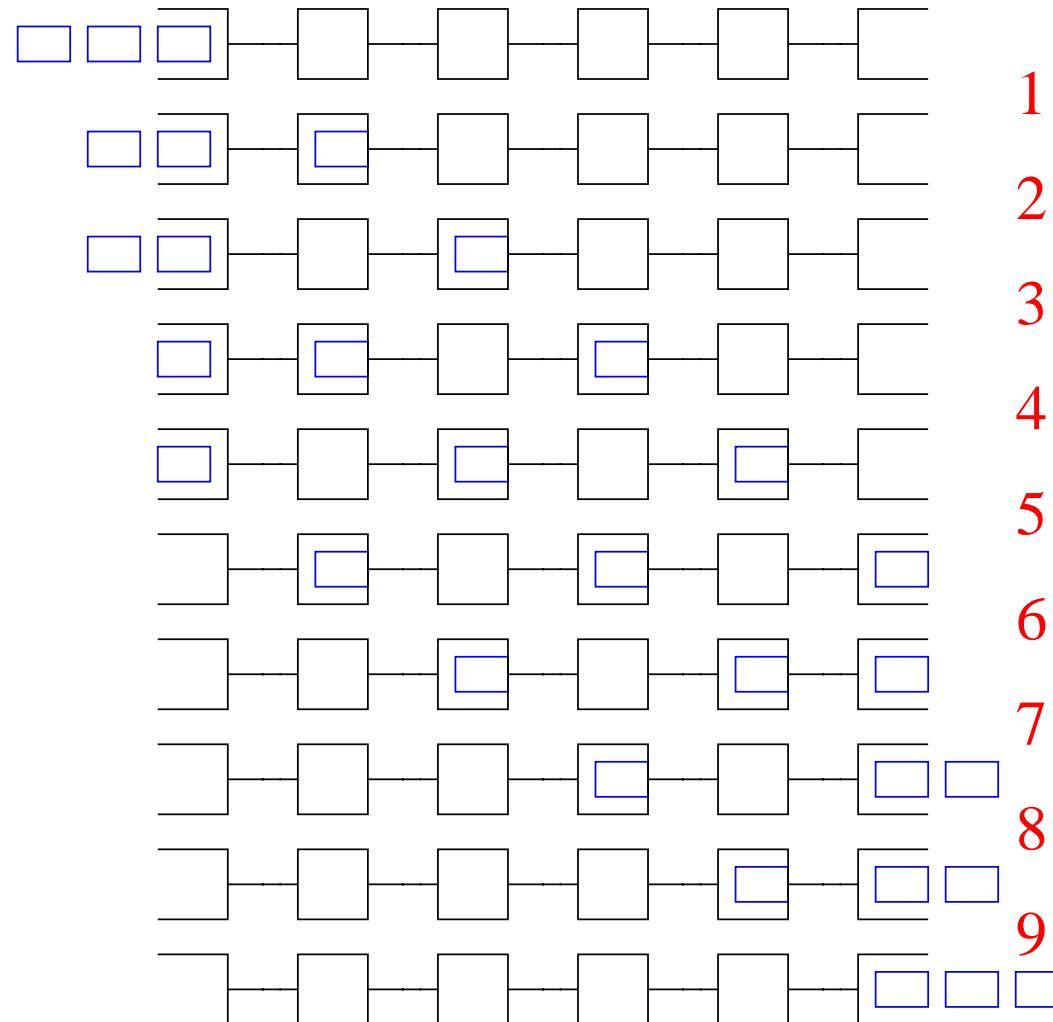
$$x @ i := \bigotimes_{i' \leq i} m @ i'$$

(auf PE i , m kann ein Vektor mit n Bytes sein.)



Einfache Pipeline

Wie bei Broadcast



Hyperwürfelalgorithmus

//view PE index i as a

// d -bit bit array

Function hcPrefix(m)

$x := \sigma := m$

for $k := 0$ **to** $d - 1$ **do**

invariant $\sigma = \bigotimes_{j=i[k..d-1]}^{i[k..d-1]} 1^k m @ j$

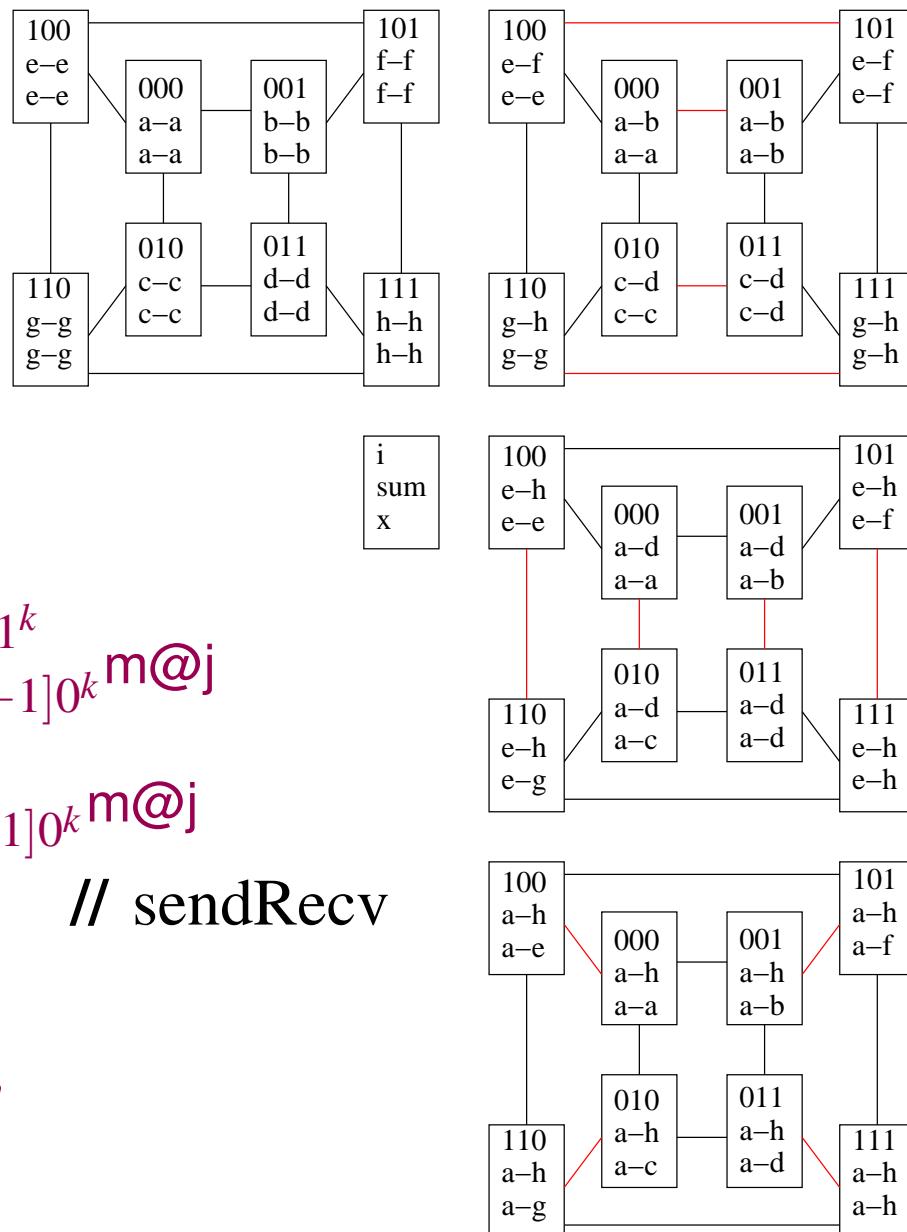
invariant $x = \bigotimes_{j=i[k..d-1]}^{i[k..d-1]} 0^k m @ j$

$y := \sigma @ (i \oplus 2^k)$ // sendRecv

$\sigma := \sigma \otimes y$

if $i[k] = 1$ **then** $x := x \otimes y$

return x



Analyse

Telefonmodell:

$$T_{\text{prefix}} = (T_{\text{start}} + nT_{\text{byte}}) \log p$$

Pipelining klappt nicht, da alle PEs immer beschäftigt.

Pipeline-Binärbaum-Präfixsummen

Infix Nummerierung (in order) der Knoten

Aufwärtsphase: wie bei Reduktion aber

PE i speichert $\sum_{j=i'}^i x @ j$

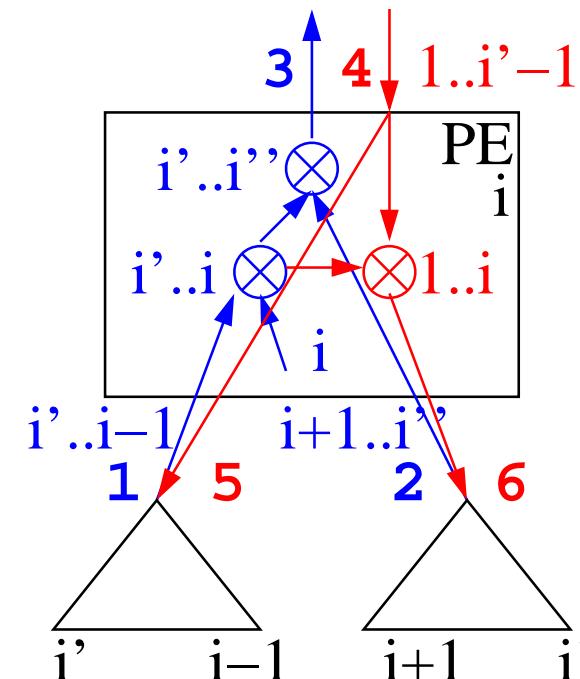
Abwärtsphase: PE i empfängt $\sum_{j=1}^{i'-1} x @ j$

(Wurzel: $= 0$!)

und reicht das nach links weiter.

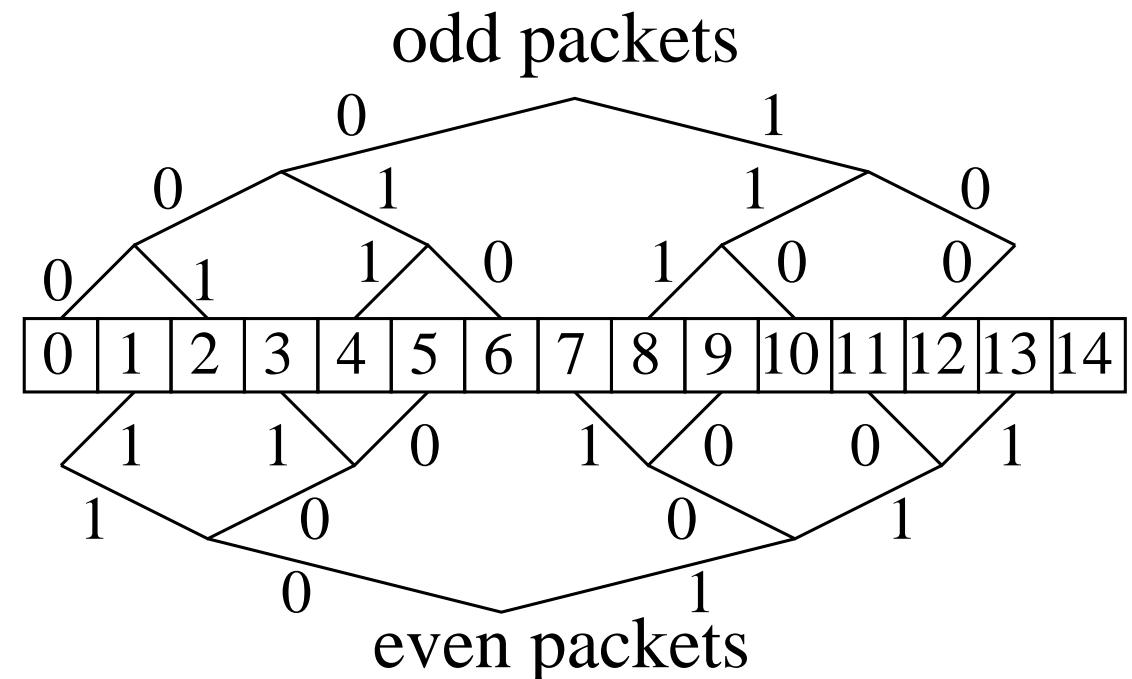
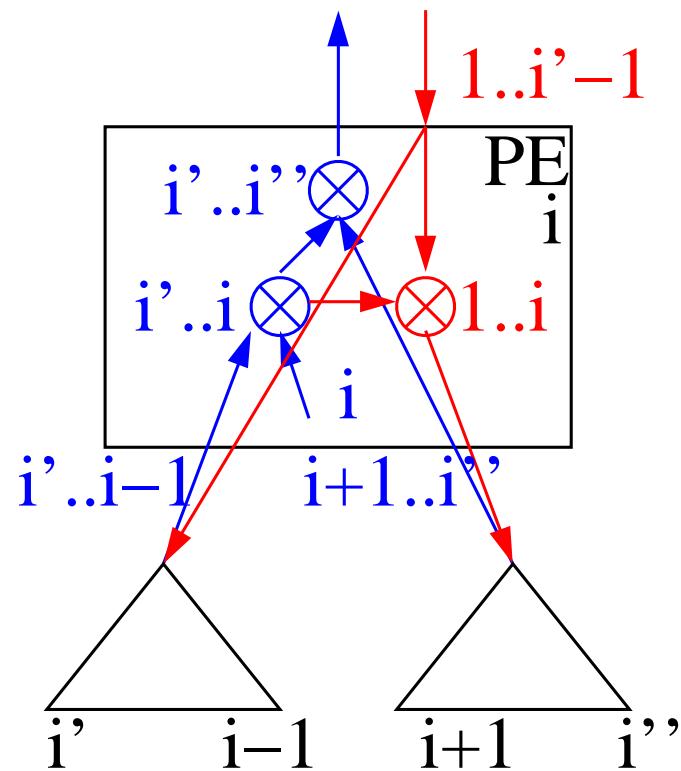
rechter Teilbaum kriegt $\sum_{j=1}^i x @ j$

Jedes PE nur $1 \times$ je Phase aktiv. \rightarrow Pipelining OK



23-Präfixsummen

Nummerierung ist Inorder-Nummerierung für **beide** Bäume !



Analyse

$$T_{\text{prefix}} \approx T_{\text{reduce}} + T_{\text{broadcast}} \approx 2T_{\text{broadcast}} = \\ 2nT_{\text{byte}} + T_{\text{start}} \cdot 4 \log p + \sqrt{8n \log p T_{\text{start}} T_{\text{byte}}}$$

Latenz senken durch Überlappen von Aufwärts und Abwärtsphase?

Verallgemeinerung:

- Beliebige auf **inorder nummerierten** Bäumen arbeitende Algorithmen einsetzbar
- ~~> ESBT funktioniert nicht?

Gossiping

Jedes PE hat eine Nachricht m der Länge n .

Am Ende soll **jedes PE alle Nachrichten** kennen.

Hyperwürfelalgorithmus

Sei ‘ \cdot ’ die Konkatenationsoperation; $p = 2^d$

PE i

$y := m$

for $0 \leq j < d$ **do**

$y' :=$ the y from PE $i \oplus 2^j$

$y := y \cdot y'$

return y

Analyse

Telefonmodell, $p = 2^d$ PEs, n Byte pro PE:

$$T_{\text{gossip}}(n, p) \approx \sum_{j=0}^{d-1} T_{\text{start}} + n \cdot 2^j T_{\text{byte}} = \log p T_{\text{start}} + (p - 1)n T_{\text{byte}}$$

All-Reduce

Reduktion statt Konkatenation.

Vorteil: Faktor zwei weniger Startups als **Reduktion plus Broadcast**

Nachteil: $p \log p$ Nachrichten.

Das ist ungünstig bei stauanfälligen Netzwerken.

All-to-all Personalized Communication

Jedes PE hat $p - 1$ Nachrichten der Länge n . Eine für jedes andere PE. Das lokale $m[i]$ ist für PE i

Hyperwürfelalgorithmus

PE i

for $j := d - 1$ **downto** 0 **do**

 Get from PE $i \oplus 2^j$ all its messages

 destined for my j -D subcube

 Move to PE $i \oplus 2^j$ all my messages

 destined for its j -D subcube

Analyse, Telefonmodell:

$$T_{\text{all-to-all}}(p, n) \approx \log p \left(\frac{p}{2} n T_{\text{byte}} + T_{\text{start}} \right)$$

vollständige Verknüpfung:

Bei großem n Nachrichten lieber einzeln schicken
(Faktor $\log p$ weniger Kommunikationsvolumen)

Der 1-Faktor-Algorithmus

[König 1936]

p ungerade:

//PE index $j \in \{0, \dots, p - 1\}$

for $i := 0$ **to** $p - 1$ **do**

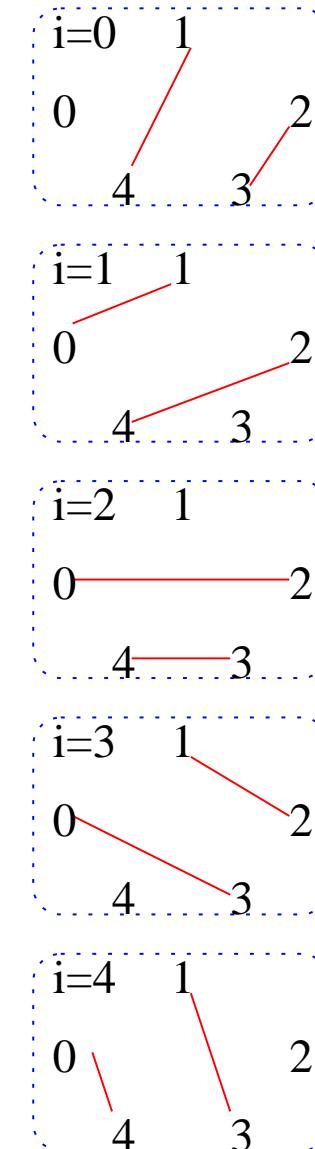
Exchange data with PE $(i - j) \bmod p$

Paarweise Kommunikation (Telefonmodell):

Der Partner des Partners von j in Runde i ist

$$i - (i - j) \equiv j \bmod p$$

Zeit: $p(nT_{\text{byte}} + T_{\text{start}})$ optimal für $n \rightarrow \infty$

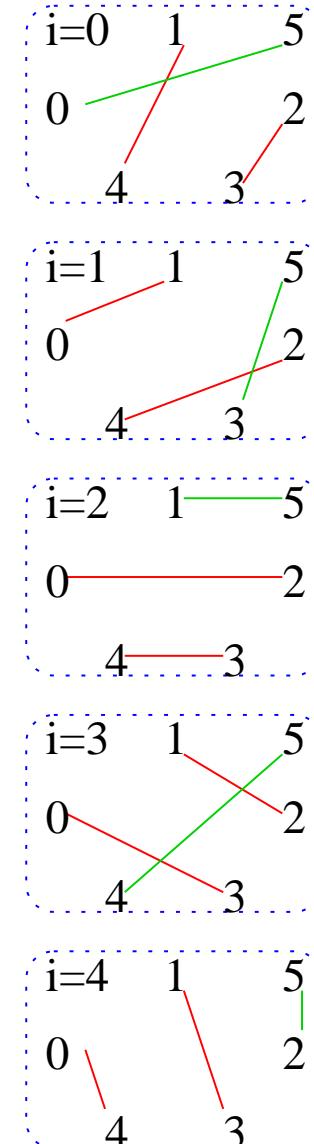


Der 1-Faktor-Algorithmus

p gerade:

```
//PE index  $j \in \{0, \dots, p - 1\}$ 
for  $i := 0$  to  $p - 2$  do
    idle :=  $\frac{p}{2}i \bmod (p - 1)$ 
    if  $j = p - 1$  then exchange data with PE idle
    else
        if  $j = \text{idle}$  then
            exchange data with PE  $p - 1$ 
        else
            exchange data with PE  $(i - j) \bmod (p - 1)$ 
```

Zeit: $(p - 1)(nT_{\text{byte}} + T_{\text{start}})$ optimal für $n \rightarrow \infty$



The Hierarchical Factor Algorithm for All-to-all Communication

Peter Sanders and Jesper Larsson Träff

Hierarchical Crossbar / Cluster of SMPs

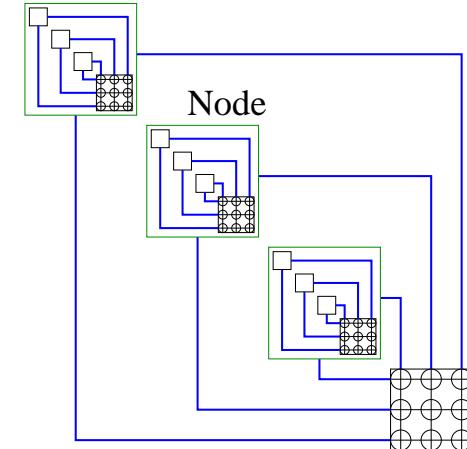
Usual Restriction:

Inter node bandwidth \leq 1-Proc intra node bandwidth

Maximally portable model:

single ported inter-node communication

Dominant architecture of scalable machines:



NEC: SX-5, SX-6, Earth Simulator ($\leq 8 \times$)

IBM: pSeries Clusters ($\leq 32 \times$)

HP: HyperPlex + SuperDome ($\leq 64 \times$)

Beowulf-like: With Hammer/Itanium2 soon $8 \times$



All-to-all

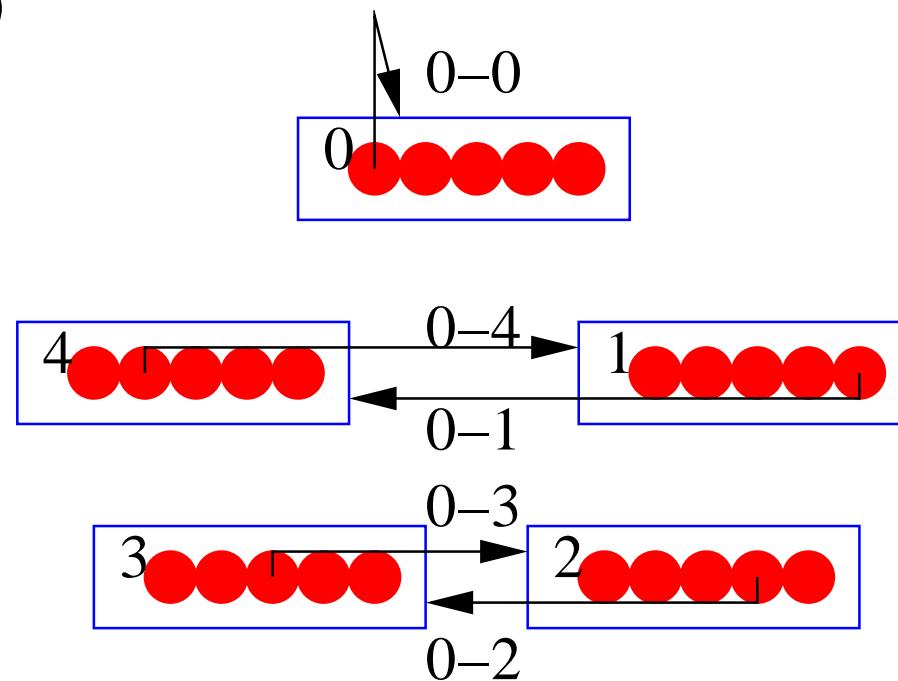
Each of p procs. has one message for each other proc.

Key **collective communication** operation in MPI

(sorting, matrix transposition, . . .)

Flat Factors

Step i : Proc $u \rightarrow i - u \bmod p$



All-to-all

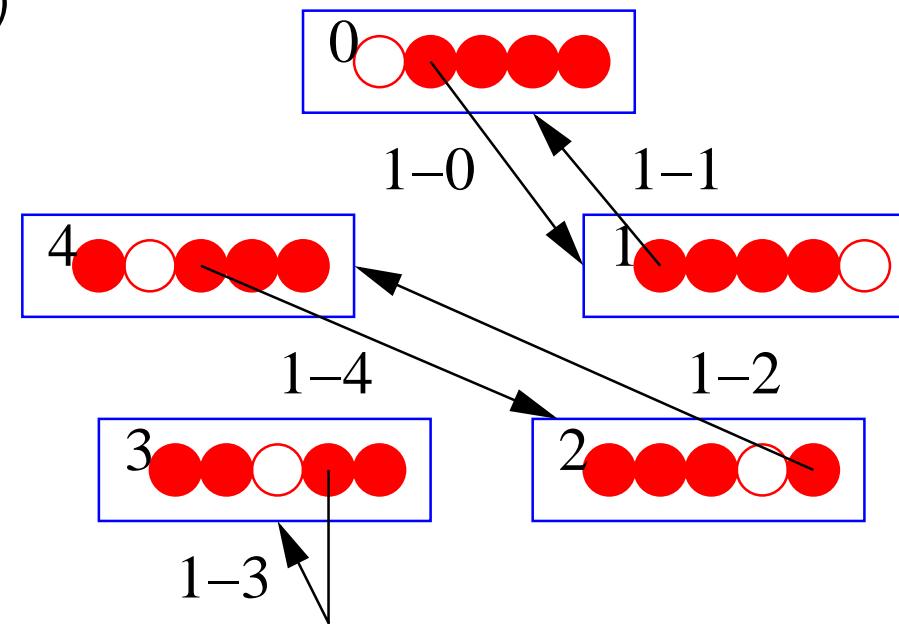
Each of p procs. has one message for each other proc.

Key **collective communication** operation in MPI

(sorting, matrix transposition, . . .)

Flat Factors

Step i : Proc $u \rightarrow i - u \bmod p$



All-to-all

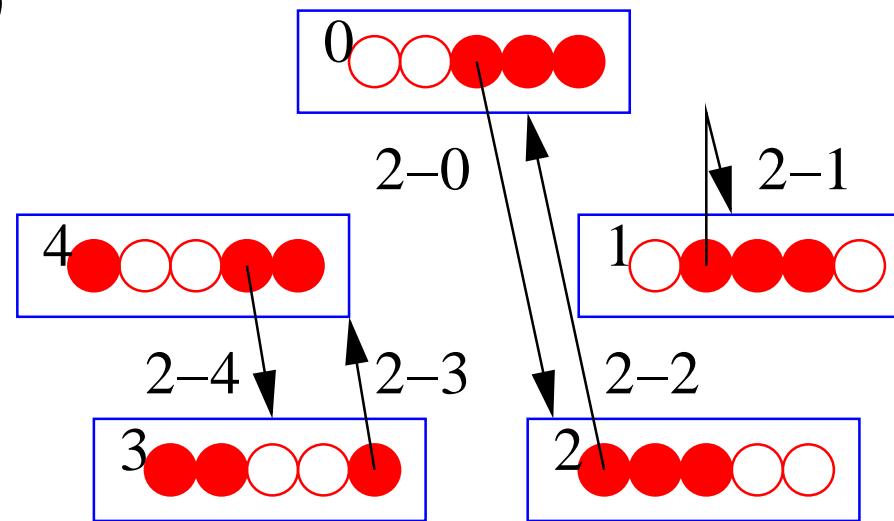
Each of p procs. has one message for each other proc.

Key **collective communication** operation in MPI

(sorting, matrix transposition, . . .)

Flat Factors

Step i : Proc $u \rightarrow i - u \bmod p$



All-to-all

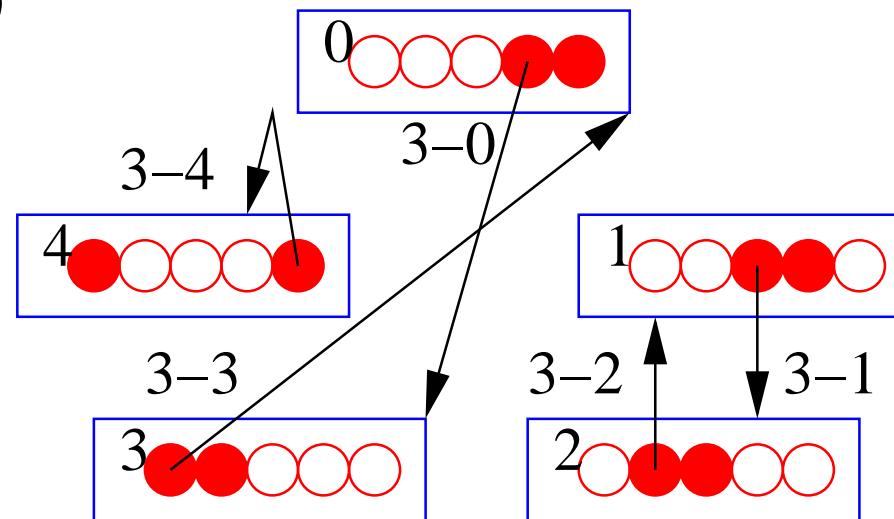
Each of p procs. has one message for each other proc.

Key **collective communication** operation in MPI

(sorting, matrix transposition, . . .)

Flat Factors

Step i : Proc $u \rightarrow i - u \bmod p$



All-to-all

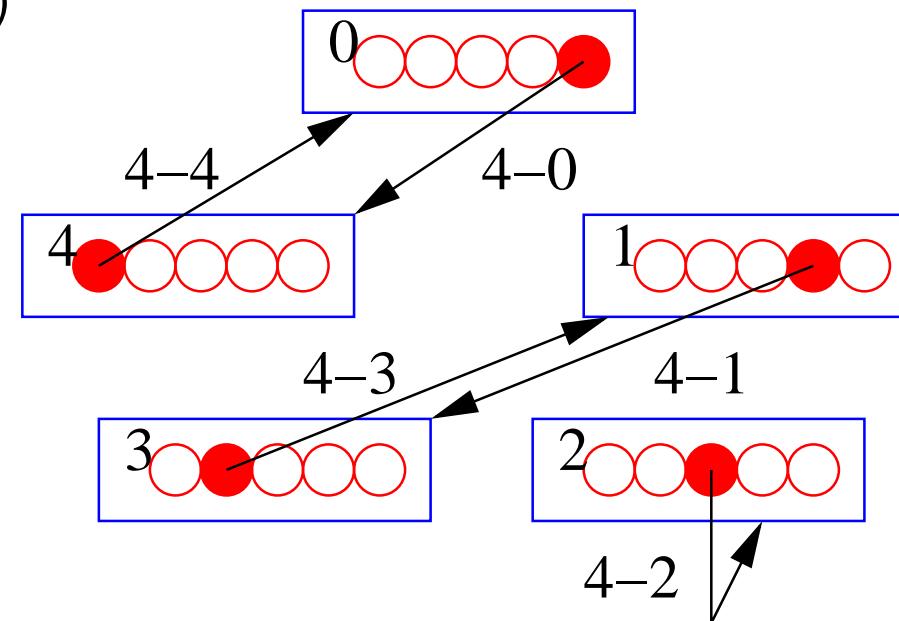
Each of p procs. has one message for each other proc.

Key **collective communication** operation in MPI

(sorting, matrix transposition, . . .)

Flat Factors

Step i : Proc $u \rightarrow i - u \bmod p$



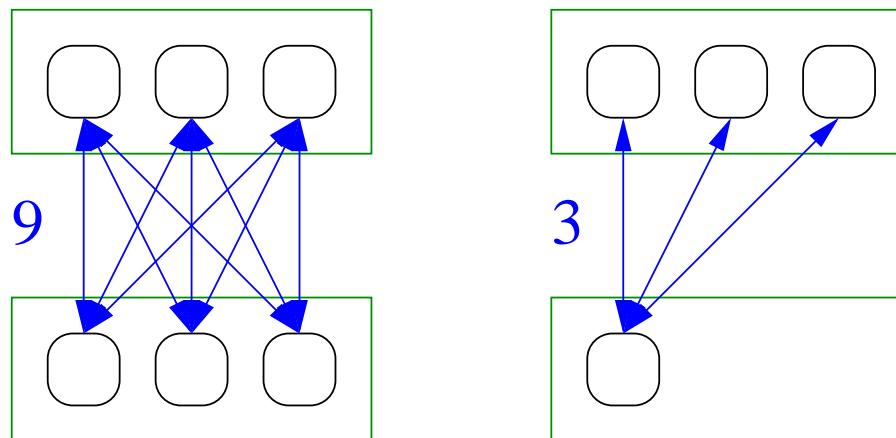
Idea 0: Ignore Hierarchy

~~~ unpredictable performance

## Idea 1- $\alpha$ : Use Factoring of Nodes

Fine if all nodes have the **same** number of participating Procs  
(not general enough for MPI)

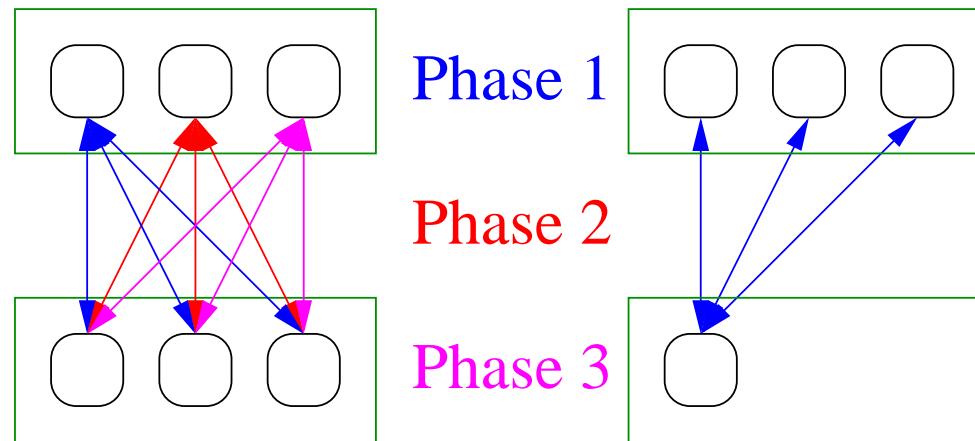
### Problem: Bad Load Balance in general



# Multiple Phases

Goal:  $\forall$  factors : full nodes **always** have the **same** load.

Consequence: Several **phases** with partial exchange



Task: Find a schedule meeting the goal

## Details

$U \preceq V$  if  $|U| < |V|$ , or  $|U| = |V| \wedge \text{num}(U) \leq \text{num}(V)$

$A \leftarrow \{0, \dots, N-1\}$

$\text{done} \leftarrow 0$

**while**  $A \neq \emptyset$  **do** // phase

**current**  $\leftarrow \min\{|U| : U \in A\}$

**for**  $i = 0, \dots, |A|-1$  **do**

**for all**  $U \preceq V \in G_A^i$  **pardo**

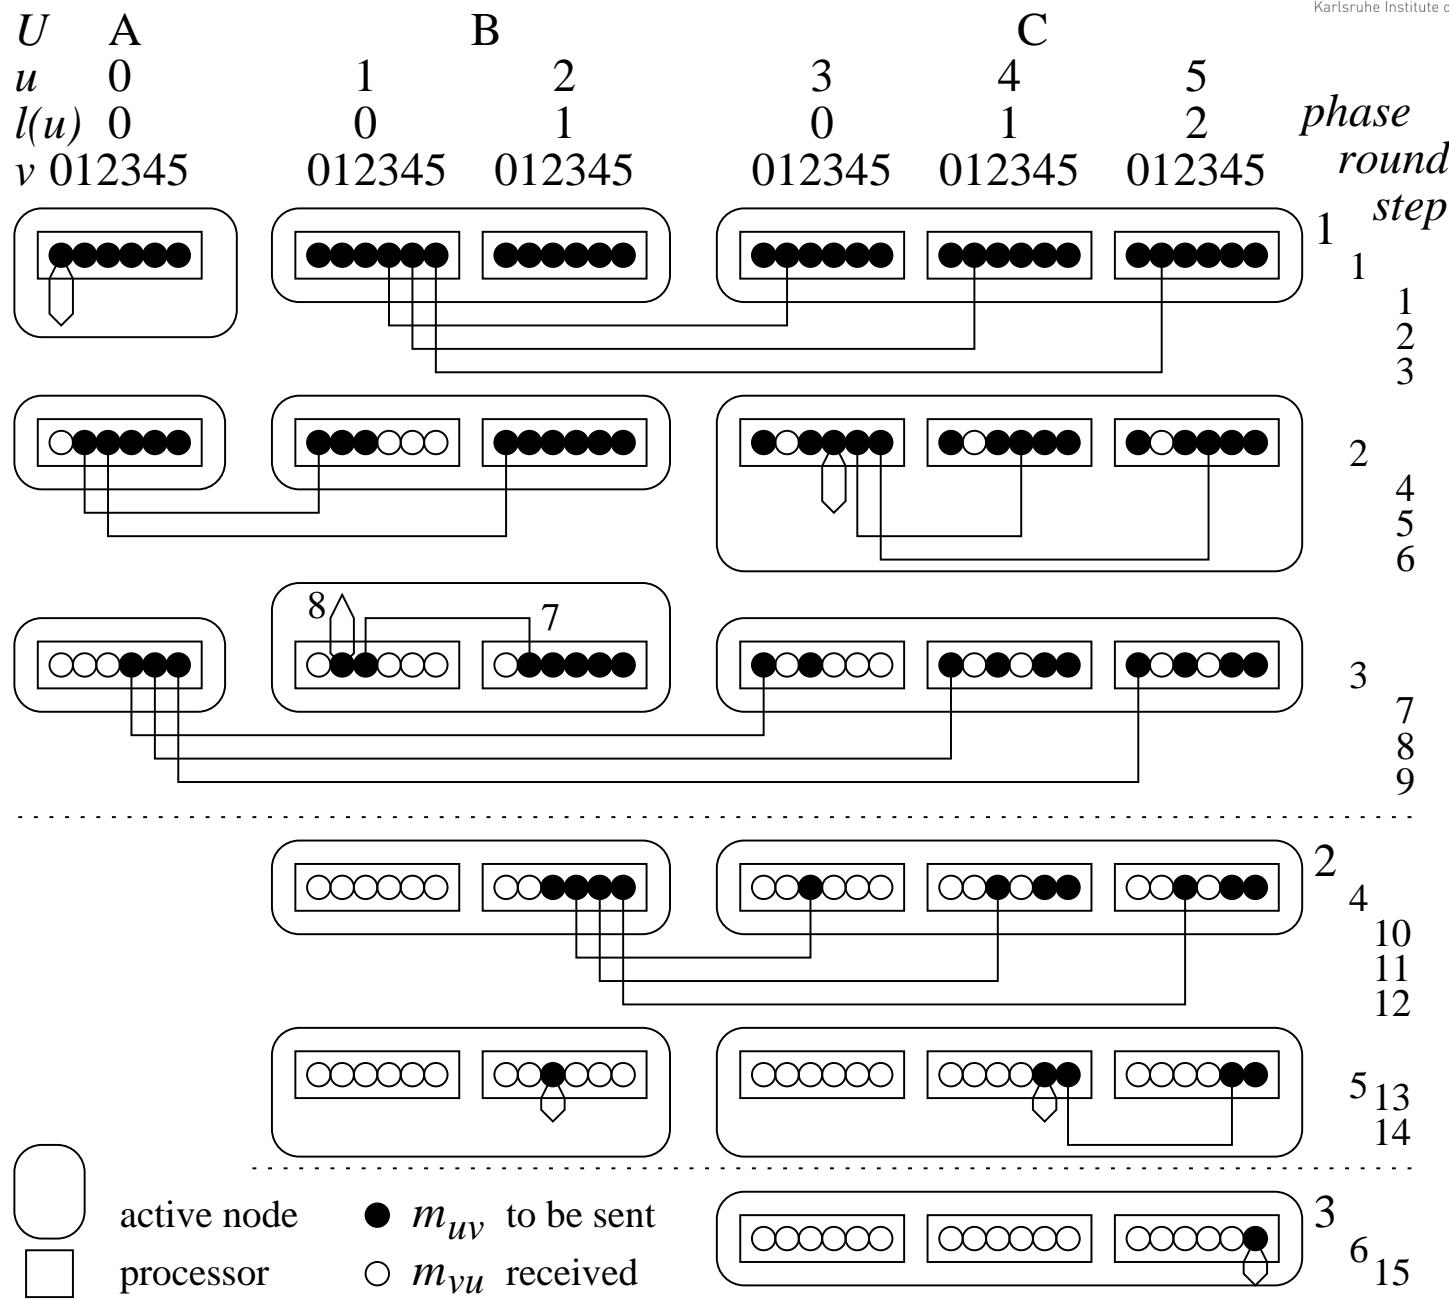
**for each**  $u \in U, \text{done} \leq l(u) < \text{current}$  **do**

**for each**  $v \in V$  **do**

**exchange** the data between  $u$  and  $v$

**done**  $\leftarrow \text{current}$

$A \leftarrow A \setminus \{U : |U| = \text{done}\}$  // prune



# Datenaustausch bei unregelmäßigen Nachrichtenlängen

- Vor allem bei all-to-all interessant → Sortieren
- Ähnliche Probleme bei inhomogenen Verbindungsnetzwerken oder Konkurrenz durch andere Jobs.

# Der Vogel-Strauß-Algorithmus

Alle Nachrichten mit asynchronen Sendeoperationen

“ins Netz stopfen”.

Alles Ankommende empfangen

Vogel-Strauß-Analyse:

BSP-Modell: Zeit  $L + gh$

Aber was ist  $L$  und  $g$  in Single-Ported Modellen? (jetzt)

Oder gleich in realen Netzwerken? (später)

## ***h*-Relation**

$h_{\text{in}}(i) :=$  Anzahl empfangener Pakete von PE  $i$

$h_{\text{out}}(i) :=$  Anzahl gesendeter Pakete von PE  $i$

simplex:  $h := \max_{i=1}^p h_{\text{in}}(i) + h_{\text{out}}(i)$

duplex:  $h := \max_{i=1}^p \max(h_{\text{in}}(i), h_{\text{out}}(i))$

Untere Schranke bei paketweiser Auslieferung:

$h$  Schritte, d.h.,

Zeit  $h(T_{\text{start}} + |\text{Paket}| T_{\text{byte}})$

# Offline $h$ -Relationen im duplex Modell

[König 1916]

Betrachte den bipartiten Multigraph

$$G = (\{s_1, \dots, s_p\} \cup \{r_1, \dots, r_p\}, E) \text{ mit}$$

$|\{(s_i, r_j) \in E\}| = \# \text{ Pakete von PE } i \text{ nach PE } j.$

Satz:  $\exists$  Kantenfärbung  $\phi : E \rightarrow \{1..h\}$ , d.h.,

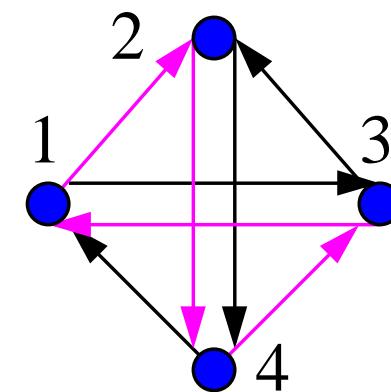
keine zwei gleichfarbigen Kanten

inzident zu einem Knoten.

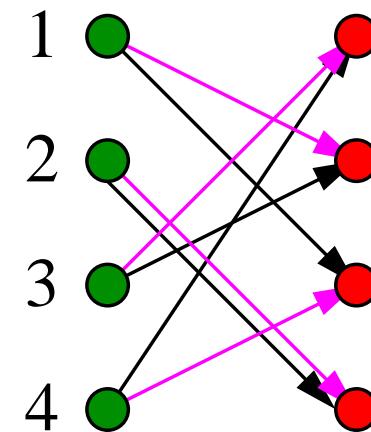
**for**  $j := 1$  **to**  $h$  **do**

Sende Nachrichten der Farbe  $j$

**optimal** wenn man paketweise Auslieferung postuliert



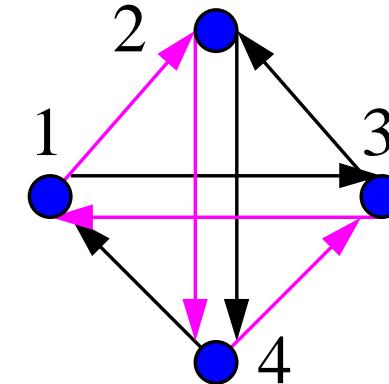
Sender      Empf.



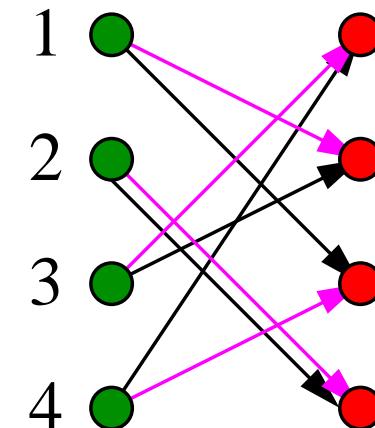
# Offline $h$ -Relationen im duplex Modell

Probleme:

- Kantenfärbung online berechnen  
ist kompliziert und teuer
- Aufteilung in Pakete erhöht Anzahl Startups



Sender      Empf.



# Offline $h$ -Relationen im Simplex-Modell

[Petersen 1891? Shannon 1949?]

Betrachte den Multigraph  $G = (\{1, \dots, p\}, E)$

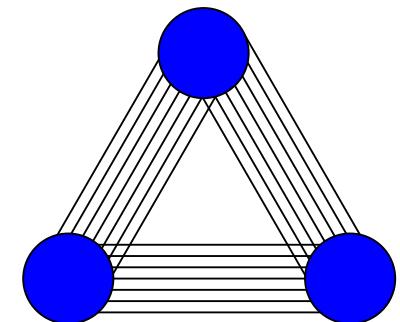
mit  $|\{\{i, j\} \in E\}| = \# \text{ Pakete zwischen PE } i \text{ und PE } j \text{ (beide Richtungen).}$

Satz:  $\exists$  Kantenfärbung  $\phi : E \rightarrow \{1..3 \lfloor h/2 \rfloor + h \bmod 2\}$

**for**  $j := 1$  **to**  $h$  **do**

    Senden Nachrichten der Farbe  $j$

optimal???



# How Helper Hasten $h$ -Relations

[Sanders Solis-Oba 2000]

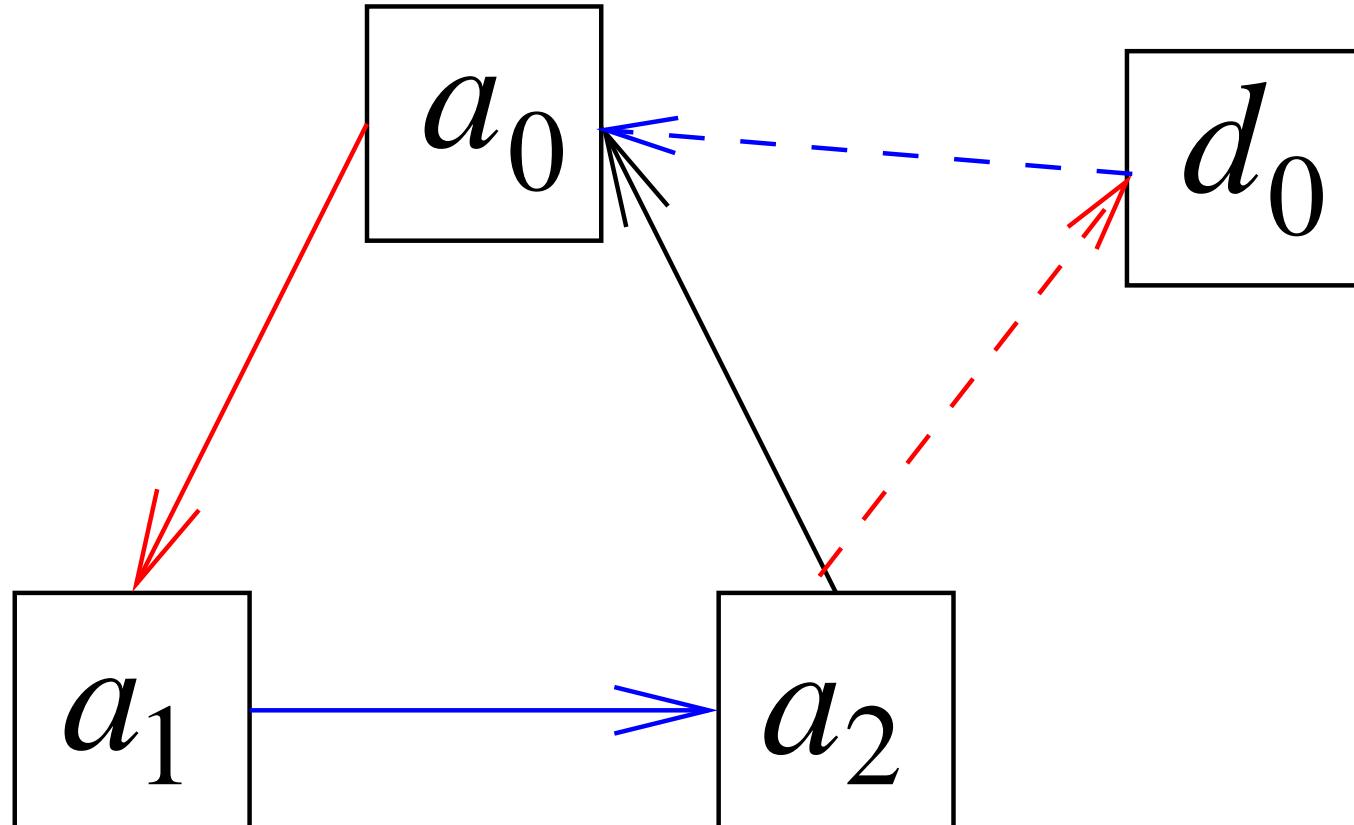
**Satz 4.** Für  $h$ -Relationen im Simplexmodell gilt

$$\#\text{steps} = \begin{cases} \frac{6}{5}(h+1) & \text{falls } P \text{ gerade} \\ \left(\frac{6}{5} + \frac{2}{P}\right)(h+1) & \text{falls } P \text{ ungerade} \end{cases} .$$

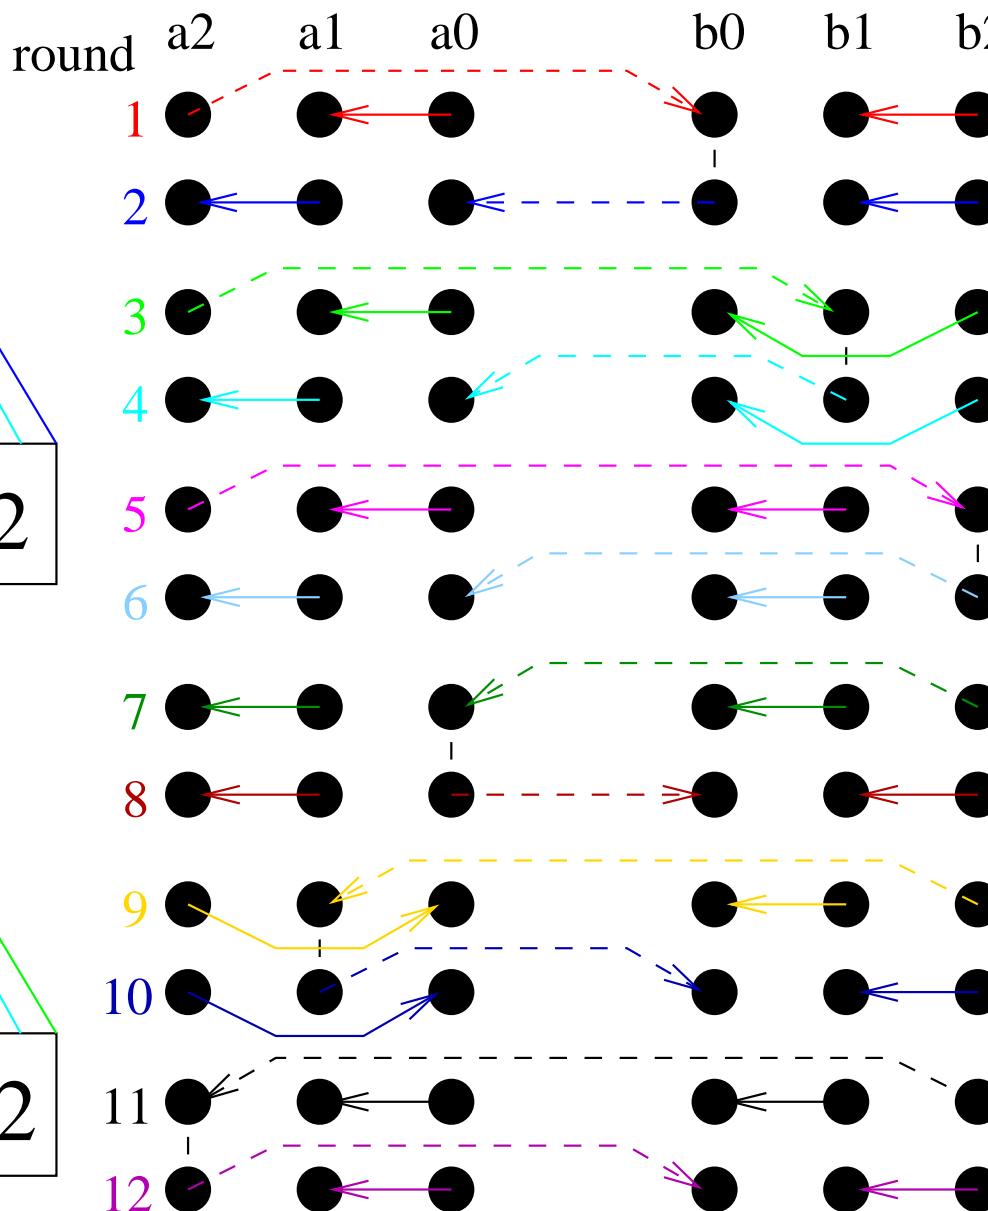
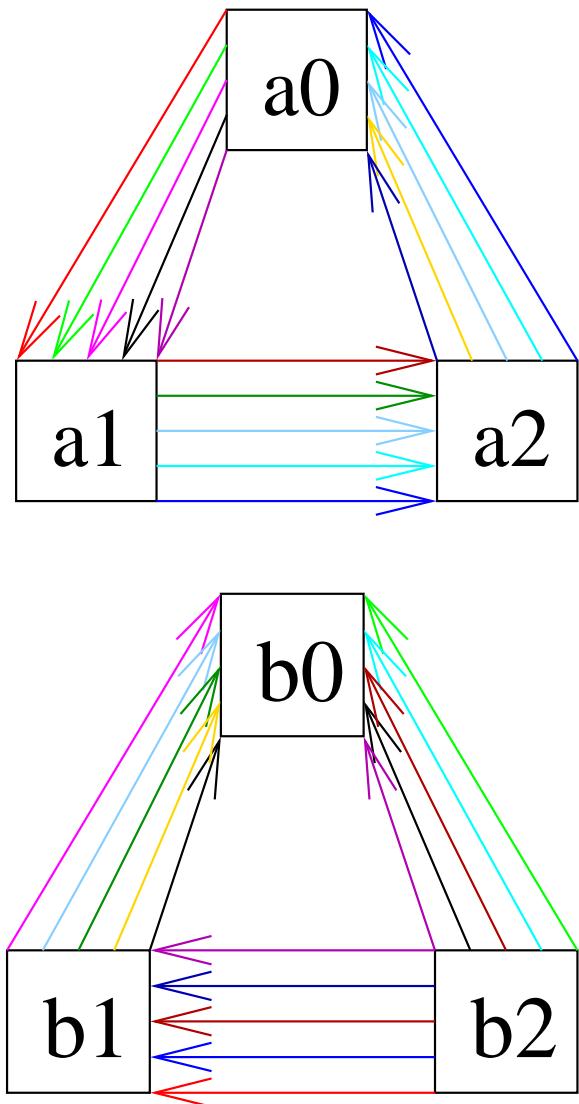
Andererseits gibt es eine *untere Schranke*

$$\#\text{steps} \geq \begin{cases} \frac{6}{5}h & \text{falls } P \text{ gerade} \\ \left(\frac{6}{5} + \frac{18}{25P}\right)h & \text{falls } P \text{ ungerade} \end{cases}$$

# Ein ganz simpler Fall



# Zwei Dreiecke



# Reduktion $h$ -Relation $\rightsquigarrow \left\lceil \frac{h}{2} \right\rceil$ 2-Relationen

- Kommunikationsrichtung erstmal ignorieren
- Verbinde Knoten mit ungeradem Grad  $\rightsquigarrow$  alle Knoten haben geraden Grad
- Eulertourtechnik: Zerlege Graph in kantendisjunkte Kreise
- Kreise im Urzeigersinn ausrichten  $\rightsquigarrow$  Eingangsgrad und Ausgangsgrad  $\leq \lceil h/2 \rceil$
- Baue bipartiten Graphen (wie gehabt)
- Färbe bipartiten Graphen
- Farbklassen in bipartitem Graph  $\rightsquigarrow$  kantendisjunkte einfache Kreise im Ursprungsgraphen (2-Relationen)
- Ursprüngliche Kommunikationsrichtung wiederherstellen

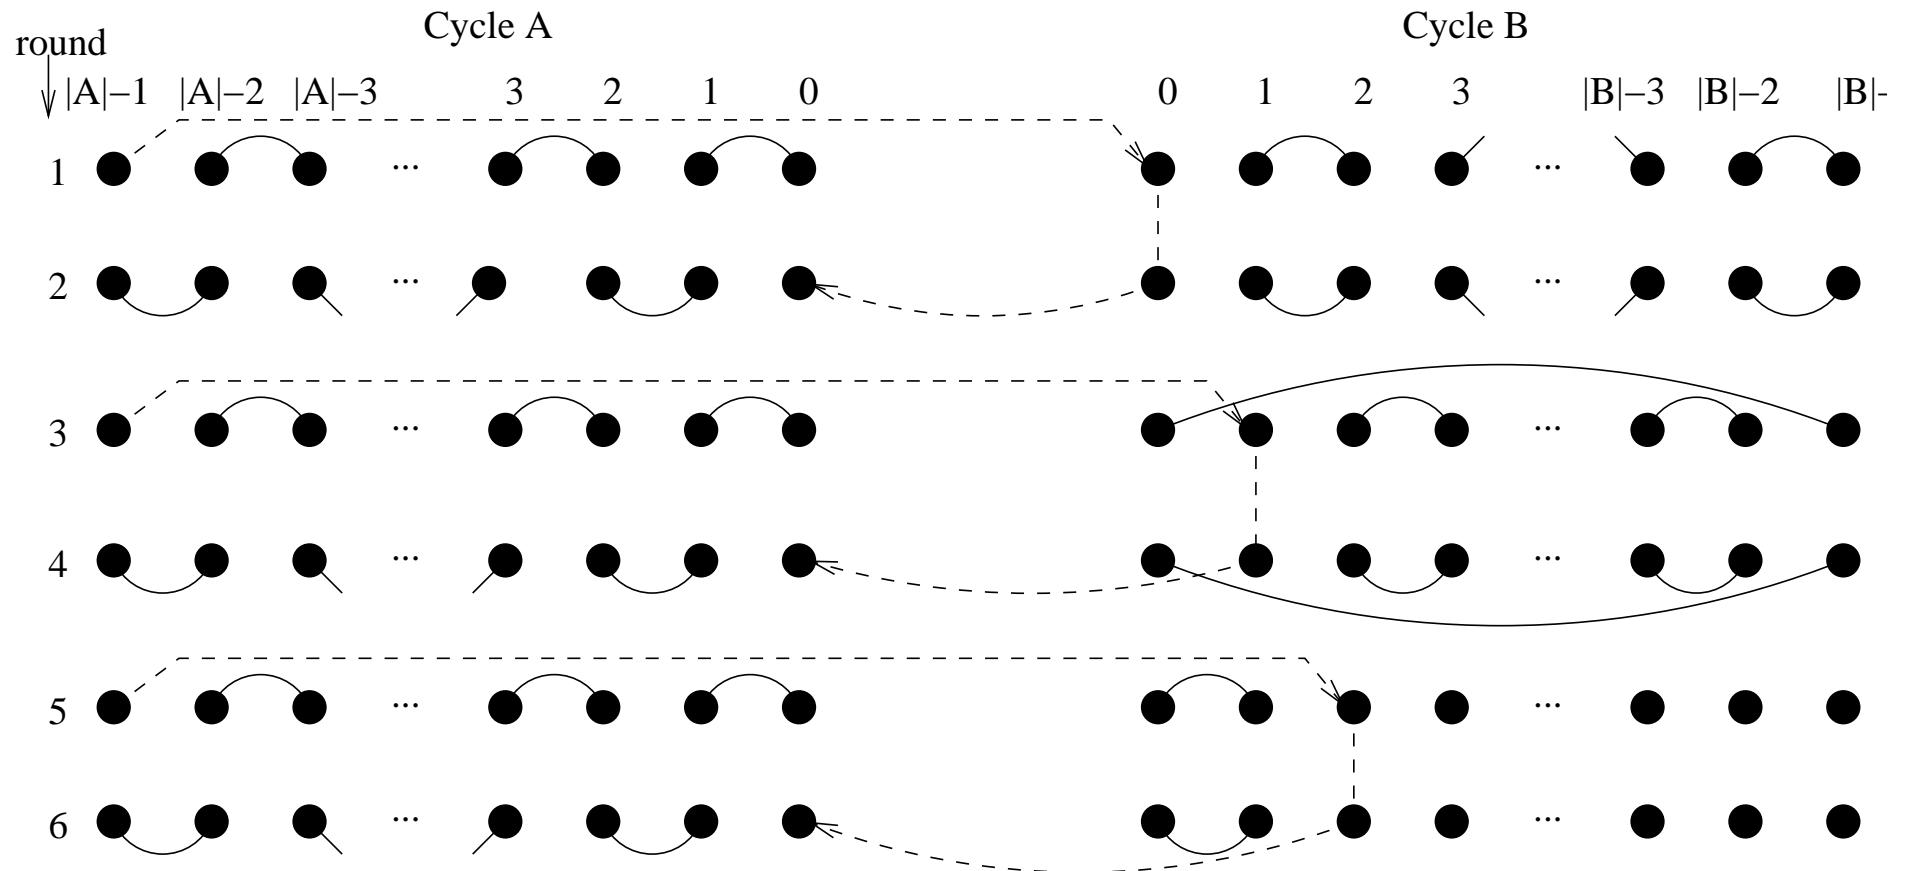
## 2-Relationen routen für gerade $p$

Paare ungerade Kreise.

1 Kreise haben nichts zu tun  $\rightsquigarrow$  einfachster Fall

# Zwei Ungerade Kreise mit $\geq 3$ Knoten

Spalte Pakete in 5 Teilstücke



Dann das ganze umdrehen

# Ungerade $p$

Idee: Lösche in jedem 2-Faktor eine Kante.

Tu dies “Immer woanders”

Sammle  $\Theta(P)$  gelöschte Kanten in einem Matching

~~ ein zusätzlicher Schritt pro  $\Theta(P)$  2-Faktoren.

# Offene Probleme

- Aufspaltung in 5 **Teilpakete** loswerden?
- Vermutung:  
Eine  $h$ -Relation mit  $\leq \frac{3}{8}hP$  Paketen kann in  $\approx h$  Schritten ausgeliefert werden.
- Startupoverheads** explizit berücksichtigen.
- Verbindungsnetzwerk** explizit berücksichtigen?
- Verteiltes Scheduling**

# Ein einfacher verteilter Algorithmus — Der Zweiphasenalgorithmus

Idee: Irreg. All-to-all  $\rightarrow 2 \times$  regular All-to-all

Vereinfachende Annahmen:

- Alle Nachrichtenlängen durch  $p$  teilbar  
(Im Zweifel aufrunden)
- Kommunikation “mit sich selbst” wird mitgezählt
- Alle PEs senden und empfangen genau  $h$  Byte  
(Im Zweifel “padding” der Nachrichten)

// $n[i]$  is length of message  $m[i]$

**Procedure** alltoall2phase( $m[1..p], n[1..p], p$ )

**for**  $i := 1$  **to**  $p$  **do**  $a[i] := \langle \rangle$

**for**  $j := 1$  **to**  $p$  **do**  $a[i] := a[i] \odot m[j][(i-1)\frac{n[j]}{p} + 1 .. i\frac{n[j]}{p}]$

$b := \text{regularAllToAll}(a, h, p)$

$\delta := \langle 1, \dots, 1 \rangle$

**for**  $i := 1$  **to**  $p$  **do**  $c[i] := \langle \rangle$

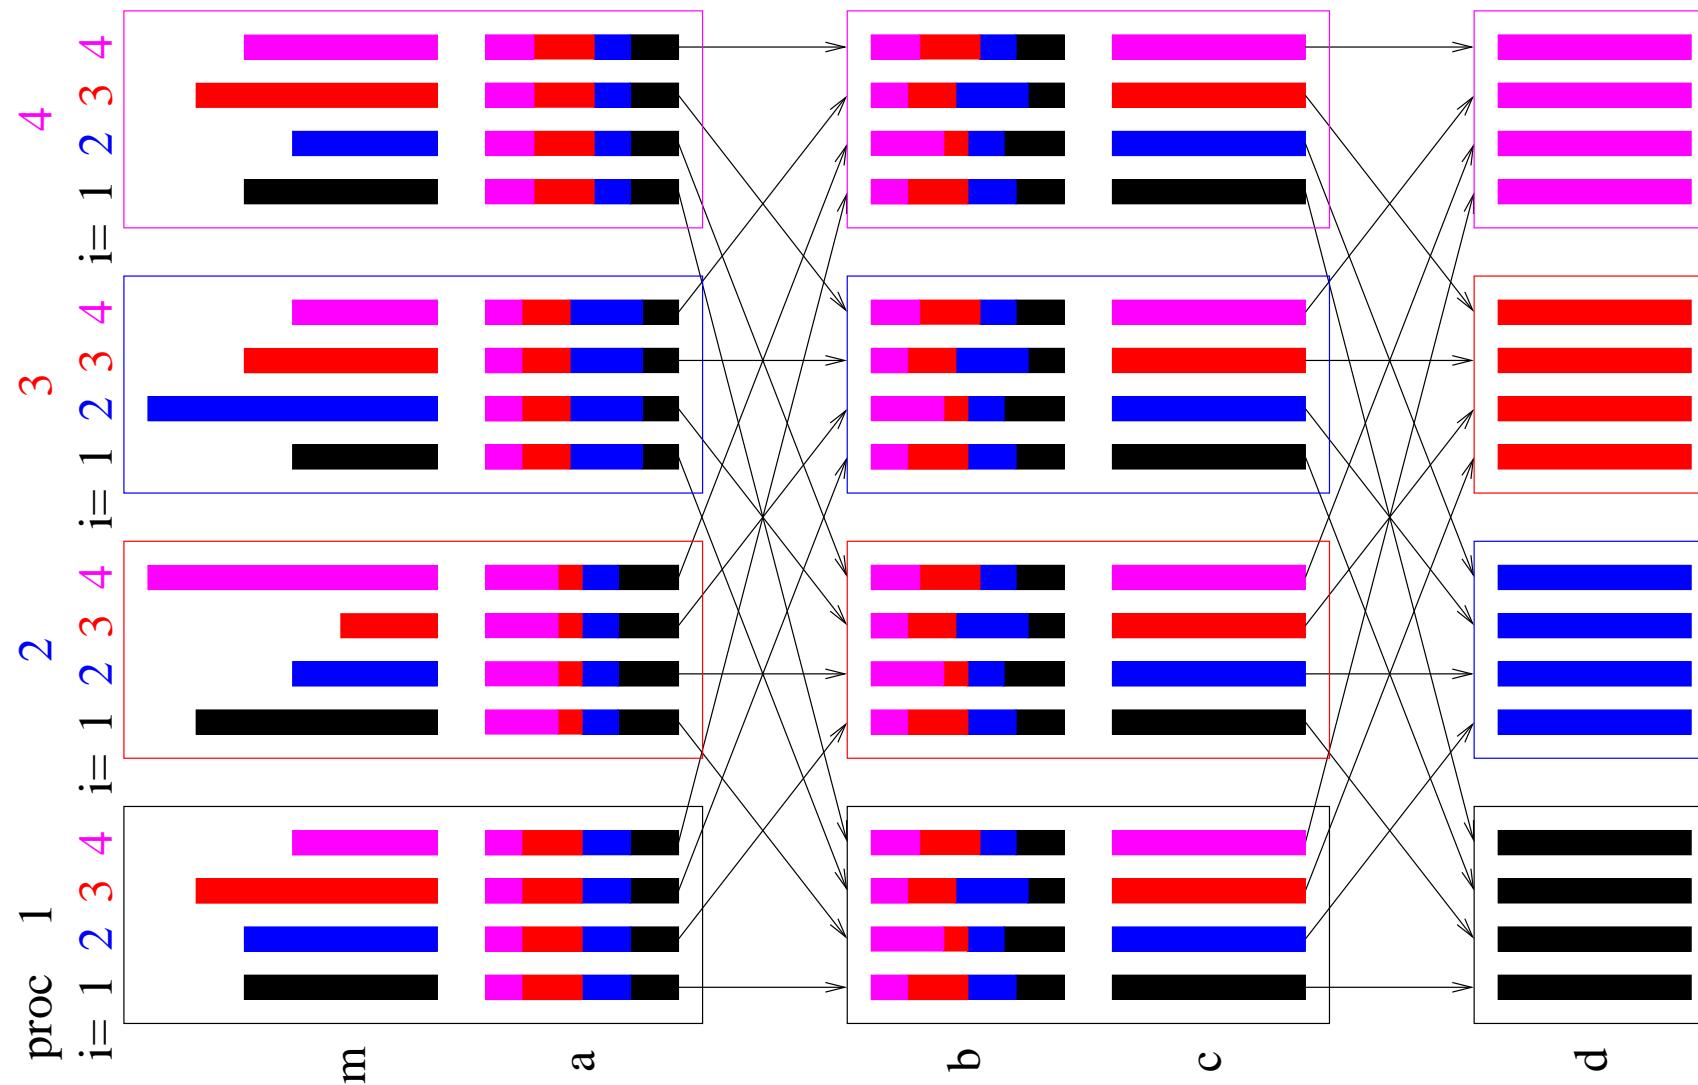
**for**  $j := 1$  **to**  $p$  **do**

$c[i] := c[i] \odot b[j][\delta[j] .. \delta[j] + \frac{n[i]@j}{p} - 1]$  // Use All-

$\delta[j] := \delta[j] + \frac{n[i]@j}{p}$  // gather to implement '@'

$d := \text{regularAllToAll}(c, h, p)$

    permute  $d$  to obtain the desired output format



# Mehr zum Zweiphasenalgorithmus

- Grosses  $p$ , kleine Nachrichten  $\rightsquigarrow$   
lokale Daten in  $\mathcal{O}(p \log p)$  Stücke aufteilen (nicht  $p^2$ ) und **zufällig** verteilen.
- Aufspaltung des Problems in **regelmäßigen** und **unregelmäßigen** Teil  $\rightsquigarrow$  nur ein Teil der Daten wir Zweiphasenprotokoll unterzogen.  
 $\rightsquigarrow$  offenes Problem: wie aufspalten?

# Ein nichtpräemptiver offline Algorithmus (simplex)

[Sanders Solis-Oba 99, unveröffentlicht]

Ziel: alle Nachrichten **direkt, als Ganzes** ausliefern.

Sei  $k :=$  Max. # Nachrichten an denen ein PE beteiligt ist.

Zeit für Ausführung des Schedule  $kT_{\text{start}} + 2hT_{\text{byte}}$

hier ist  $h$  in Byte gemessen!

# Abstrakte Beschreibung

$s :=$  empty schedule

$M :=$  set of messages to be scheduled

**while**  $M \neq \emptyset$  **do**

$t := \min \{t : \exists m \in M : m\text{'s src and dest are idle at time } t\}$

$s := s \cup \text{"start sending } m \text{ at time } t\text{"}$

$M := M \setminus \{m\}$

Kann implementiert werden, so dass pro Nachricht Zeit für  $\mathcal{O}(1)$

Prioritätslistenoperationen und eine  $p$ -bit Bitvektoroperation anfällt.

~~> praktikabel für Nachrichtenlängen  $\gg p$  und moderate  $p$ .

# Offene Probleme zum nichtpräemptiven offline Algorithmus

- implementieren, ausmessen, verwenden, z.B. sortieren, Konstruktion v. Suffix-Arrays
- Bessere Approximationssalgorithmen?
- Parallelle Scheduling-Algorithmen

## Zusammenfassung: All-to-All

Vogel-Strauss: Abwälzen auf **online, asynchrones** Routing.

Gut wenn das gut implementiert ist.

Regular+2Phase: Robustere Lösung. Aber, Faktor 2 stört, viel Umkopieraufwand.

Nichtpräemptiv: Minimiert Startups, Kommunikationsvolumen. Faktor 2 (worst case). Zentralisierte Berechnung stört.

Gut bei wiederholten identischen Problemen.

Färbungsbasierte Algorithmen: Fast optimal bei großen Paketen.

Komplex. Verteilte Implementierung? Aufspalten in Pakete stört.

**Vergleich** von Ansätzen?

# Noch allgemeinere kollektive Kommunikation: Multicommodity Multicasting

(Hyper?)graph  $G = (V, E)$ , (mit Kantenkapazitäten?)

Quellen:  $s_1, \dots, s_k$

Empfängerermengen:  $\textcolor{violet}{T}_i \subseteq V$

$s_i$  sendet Nachricht der Länge  $n_i$  an alle Knoten in  $T_i$

In Parallelrechnern wenig gebräuchlich aber für Anwendungen in Storage Area Networks vorgeschlagen.

# Parallele Prioritätslisten

Verwalte eine Menge  $M$  von Elementen.  $n = |M|$ . Anfangs leer

# Binary Heaps (sequentiell)

**Function** deleteMin     $e := \min M$ ;    $M := M \setminus \{e\}$ ;   **return**  $e$  //  $\mathcal{O}(\log n)$

# Parallele Prioritätslisten, Ziel

insert\*: Jedes PE fügt konstant viele Elemente ein,  
Zeit  $\mathcal{O}(\log n + \log p)$ ?

deleteMin\*: lösche die  $p$  kleinsten Elemente,  
Zeit  $\mathcal{O}(\log n + \log p)$ ?

Nicht hier: asynchrone Variante: Jeder kann jederzeit einfügen oder  
deleteMin machen.

Semantik:  $\exists$  zeitliche Anordnung der Operationen, die mit der  
sequentiellen Queue übereinstimmt.

# Anwendungen

- Prioritätsgestriebenes Scheduling von unabhängigen Jobs
- Best first Branch-and-bound:  
Finde beste Lösung in einem großen, implizit definierten Baum.  
(später mehr)
- Simulation diskreter Ereignisse

# Naive Implementierung

PE 0 verwaltet eine sequentielle Prioritätsliste

Alle anderen stellen Anfragen

insert:  $\Omega(p(T_{\text{start}} + \log n))$

deleteMin:  $\Omega(p(T_{\text{start}} + \log n))$

# Branch-and-Bound

$H$ : Baum  $(V, E)$  mit beschränktem maximalen Knotengrad

$c(v)$ : Knotenkosten — steigen auf jedem Abwärtspfad monoton an

$v^*$ : Blatt mit minimalen Kosten

$\tilde{V}$ :  $\{v \in V : v \leq v^*\}$

$m$ :  $|\tilde{V}|$  Vereinfachung:  $\Omega(p \log p)$

$h$ : Tiefe von  $\tilde{H}$  (durch  $\tilde{V}$  knoteninduzierter Teilgraph von  $H$ ).

$T_x$  Zeit für Generierung der Nachfolger eines Knotens

$T_{\text{coll}}$  obere Schranke für Broadcast, Min-Reduktion, Prefix-Summe,  
routing ein Element von/zu zufälligem Partner.  
 $\mathcal{O}(T_{\text{start}} \log p)$  auf vielen Netzwerken.

# Sequentielles Branch-and-Bound

$Q = \{\text{root node}\} : \text{PriorityQueue}$  // frontier set

$c^* = \infty$  // best solution so far

**while**  $Q \neq \emptyset$  **do**

select some  $v \in Q$  and remove it

**if**  $c(v) < c^*$  **then**

**if**  $v$  is a leaf node **then** process new solution;  $c^* := c(v)$

**else** insert successors of  $v$  into  $Q$

$$T_{\text{seq}} = m(T_x + \mathcal{O}(\log m))$$

# Paralleles Branch-and-Bound

```
 $Q = \{\text{root node}\} : \text{ParallelPriorityQueue}$ 
 $c^* = \infty$  // best solution so far

while  $Q \neq \emptyset$  do
     $v := Q.\text{deleteMin*}$  // SPMD!
    if  $c(v) < c^*$  then
        if  $v$  is a leaf node then
            process new solution
            update  $c^*$  // Reduction
        else insert successors of  $v$  into  $Q$ 
```

# Analyse

Satz:  $T_{\text{par}} = \left(\frac{m}{p} + h\right)(T_x + \mathcal{O}(T_{\text{queueOp}}))$

Fall 1 (höchstens  $m/p$  Iterationen): Alle bearbeiteten Knoten sind in  $\tilde{V}$

Fall 2 (höchstens  $h$  Iterationen): Knoten ausserhalb von  $\tilde{V}$  werden bearbeitet → die maximale Pfadlänge von einem Knoten in  $Q$  zur optimalen Lösung wird reduziert.

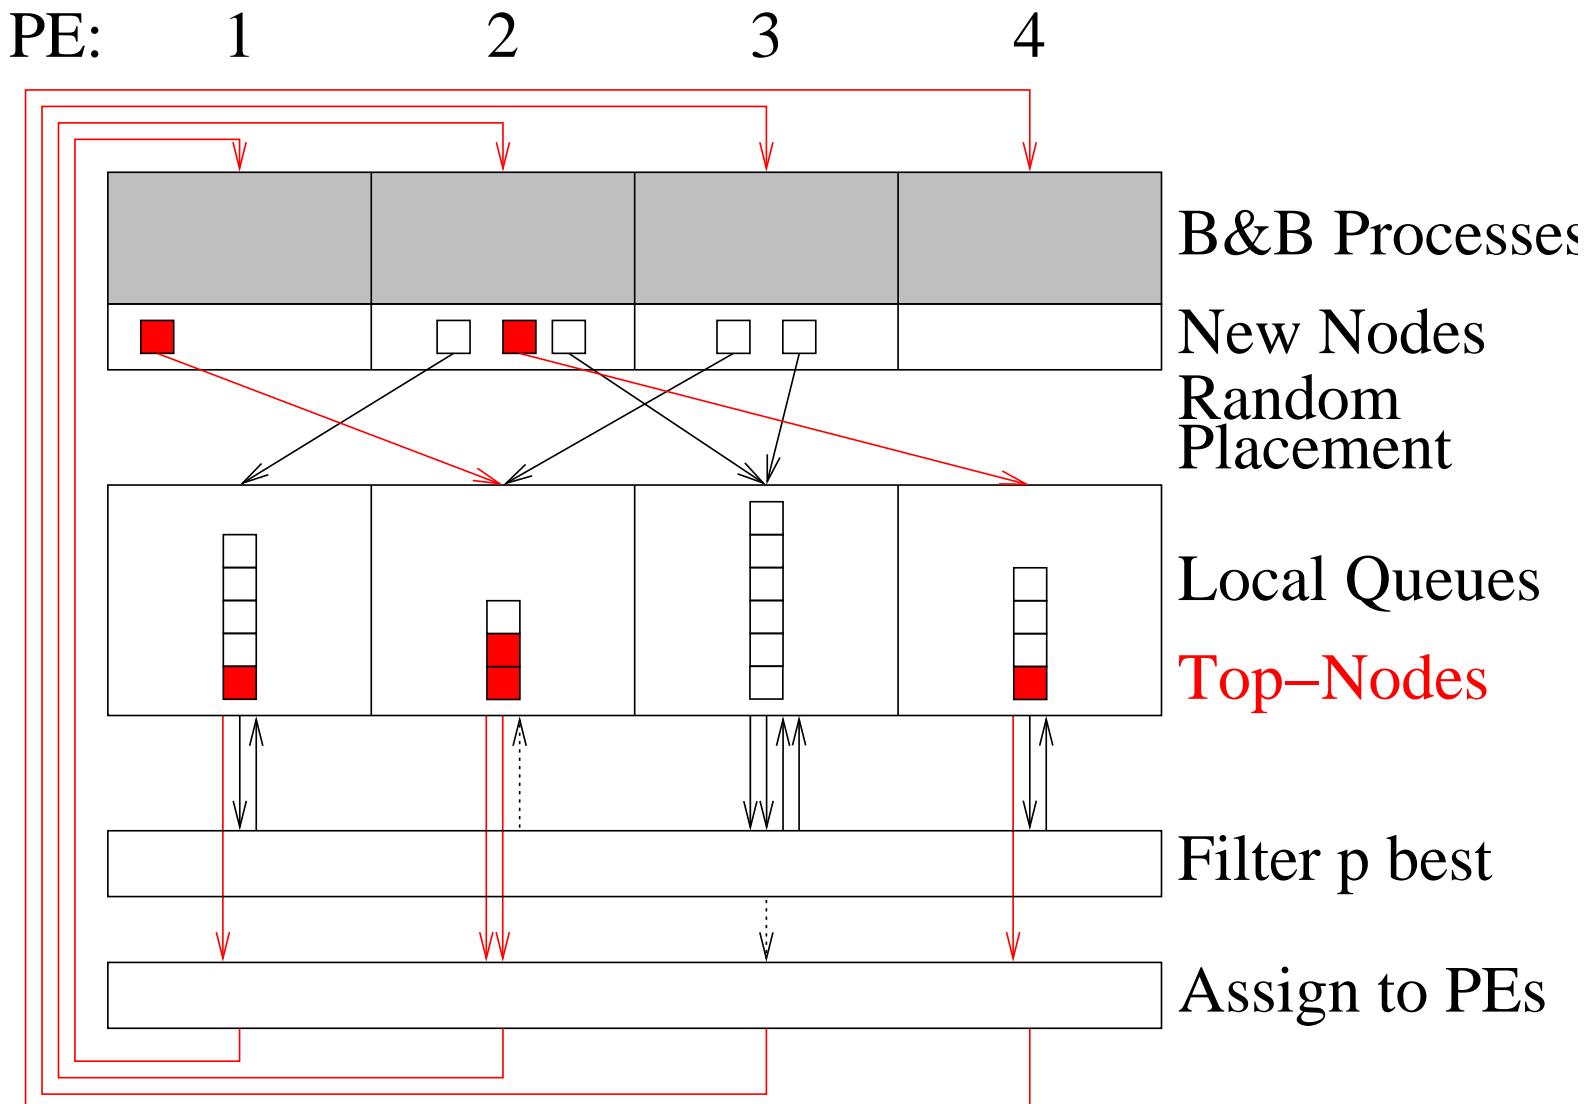
□

# Der Algorithmus von Karp und Zhang

```
 $Q = \{\text{root node}\} : \text{PriorityQueue}$  // local!
 $c^* = \infty$  // best solution so far
while  $\exists i : Q@i \neq \emptyset$  do
     $v := Q.\text{deleteMin*}$  // local!
    if  $c(v) < c^*$  then
        if  $v$  is a leaf node then
            process new solution
         $c^* := \min_i c(v)@i$  // Reduction
        else for each successor  $v'$  of  $v$  do
            insert  $v$  into  $Q@i$  for random  $i$ 
```

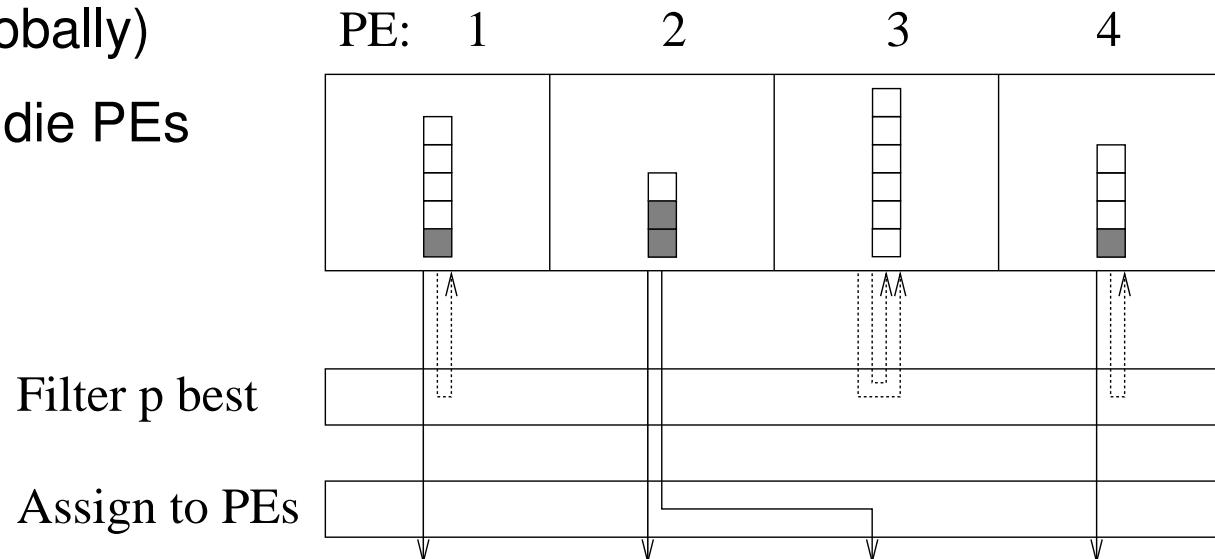
Satz: Expected time is **asymptotically** optimal

# Unser Ansatz



# Parallele Prioritätslisten: Ansatz

- Die Queue ist die Vereinigung **lokaler** queues
- **Einfügen** schickt neue Elemente an zufällige lokale Queues
  - Intuition: jedes PE braucht eine repräsentative Sicht der Dinge
- **deleteMin\*** sucht die **global** kleinsten Elemente
  - (act locally think globally)
  - und verteilt sie auf die PEs



# Einfache Probabilistische Eigenschaften

Mit hoher Wahrscheinlichkeit (**mhw**):

hier  $\geq 1 - p^{-c}$  für eine Konstante  $c$  unserer Wahl)

- mhw nur  $\mathcal{O}\left(\frac{\log p}{\log \log p}\right)$  Elemente pro lokaler Queue beim **Einfügen**
- mhw enthalten die  $\mathcal{O}(\log p)$  kleinsten Elemente jeder lokalen queue die  $p$  **global** besten Elemente
- mhw enthält keine lokale queue mehr als  $\mathcal{O}(n/p + \log p)$  Elemente

Beweis: Chernoff-Schranken rauf und runter.  
(Standardsituation. Bälle in Kisten)

# Parallele Realisierung I

Sei  $T_{\text{coll}} :=$  obere Schranke für

Broadcast, Min-Reduktion, Prefix-Summe, routing ein Element von/zu  
zufälligem Partner.

$\mathcal{O}(T_{\text{start}} \log p)$  auf vielen Netzwerken.

## Einfügen

Verschicken:  $T_{\text{coll}}$

Lokal einfügen:  $\mathcal{O}\left(\frac{\log p}{\log \log p} \cdot \log \frac{n}{p}\right)$ .

(Besser mit “fortgeschrittenen” lokalen queues. Vorsicht:  
amortisierte Schranken reichen nicht.)

# Parallele Realisierung I

## deleteMin\*

**Procedure** deleteMin\*( $Q_1, p$ )

$Q_0 :=$  the  $\mathcal{O}(\log p)$  smallest elements of  $Q_1$

$M := \text{select}(Q_0, p)$  // später

enumerate  $M = \{e_1, \dots, e_p\}$

assign  $e_i$  to PE  $i$  // use prefix sums

**if**  $\max_i e_i > \min_j Q_1 @ j$  **then** expensive **special case** treatment

empty  $Q_0$  back into  $Q_1$

# Analyse

Lokal entfernen:  $\mathcal{O}\left(\log p \log \frac{n}{p}\right)$

Selektion:  $\mathcal{O}(T_{\text{coll}})$  mhw todo

$M$  aufzählen:  $\mathcal{O}(T_{\text{coll}})$

Ergebnisse ausliefern:  $\mathcal{O}(T_{\text{coll}})$  (zufällige Quellen)

Verifizieren:  $\mathcal{O}(T_{\text{coll}}) + (\text{etwas polynomiell in } p) \cdot (\text{eine polynomiell kleine Wahrscheinlichkeit})$

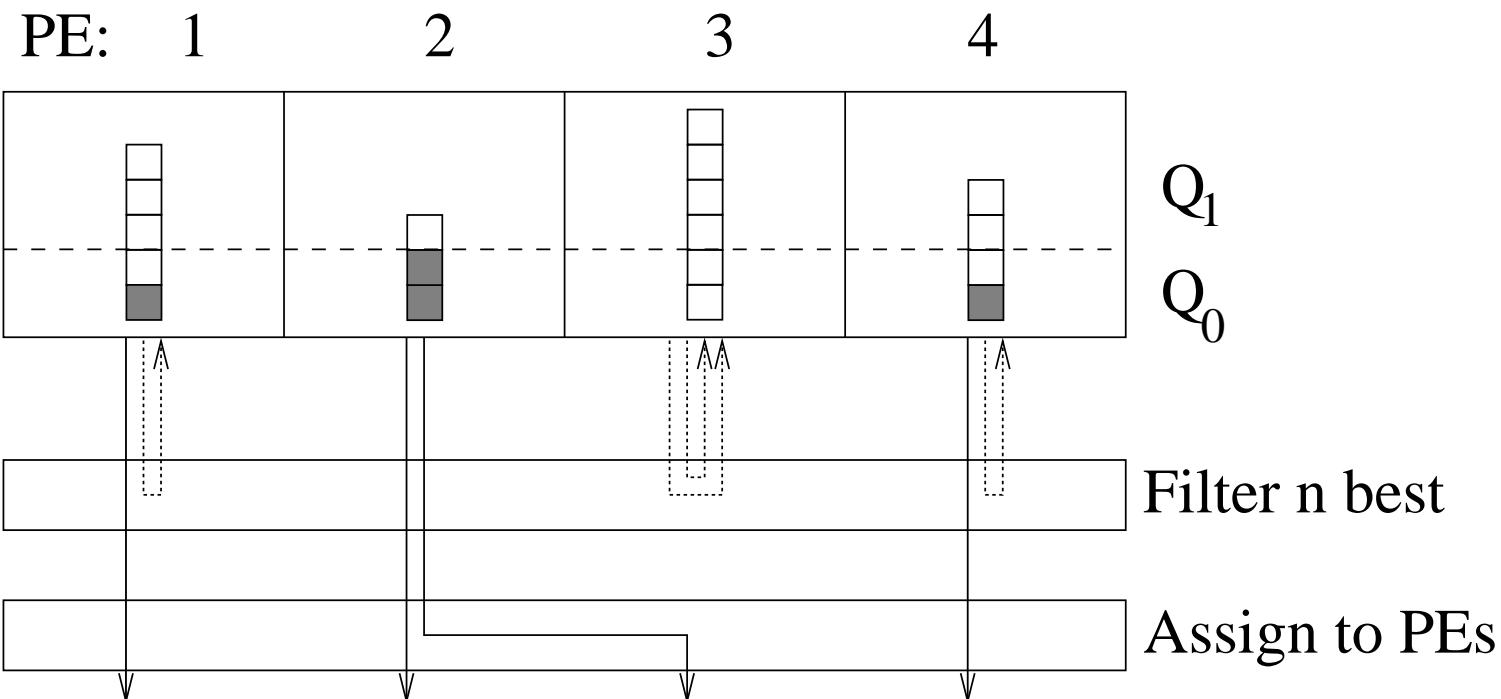
Lokal einfügen:  $\mathcal{O}\left(\frac{\log p}{\log \log p} \log \frac{n}{p}\right)$

# Parallele Realisierung II

Idee vermeide Ping-Pong der  $\mathcal{O}(\log n)$  kleinsten Elemente.

Zweiteilung der queue in  $Q_0$  und  $Q_1$ ,  $|Q_0| = \mathcal{O}(\log p)$ .

Invariante: mhw  $|Q_0| = \mathcal{O}(\log p)$



# Parallele Realisierung II

## Einfügen

Verschicken:  $T_{\text{coll}}$

Lokal einfügen: mischen von  $Q_0$  und neuen Elementen

$$\mathcal{O}(\log p) \text{ mhw.}$$

Aufräumen: Alle  $\log p$  Iterationen  $Q_0$  leeren.

~~ Kosten  $\mathcal{O}\left(\log p \log \frac{m}{p}\right)$  pro  $\log p$  Iterationen

~~ mittlere Kosten  $\mathcal{O}\left(\log \frac{m}{p}\right)$

# Parallele Realisierung II

## deleteMin\*

**Procedure** deleteMin\*( $Q_0, Q_1, p$ )

**while**  $|\{e \in \check{Q}_0 : e < \min \check{Q}_1\}| < p$  **do**

$Q_0 := Q_0 \cup \{\text{deleteMin}(Q_1)\}$

$M := \text{select}(Q_0, p)$  // später

    enumerate  $M = \{e_1, \dots, e_p\}$

    assign  $e_i$  to PE  $i$  // use prefix sums

# Analyse

Lokal entfernen: erwartet  $\mathcal{O}(1)$  Iterationen  $\rightsquigarrow \mathcal{O}\left(T_{\text{coll}} + \log \frac{n}{p}\right)$

Selektion:  $\mathcal{O}(T_{\text{coll}})$  mhw todo

$M$  aufzählen:  $\mathcal{O}(T_{\text{coll}})$

Ergebnisse ausliefern:  $\mathcal{O}(T_{\text{coll}})$  (zufällige Quellen)

# Ergebnis

insert\*: erwartet  $\mathcal{O}\left(T_{\text{coll}} + \log \frac{n}{p}\right)$

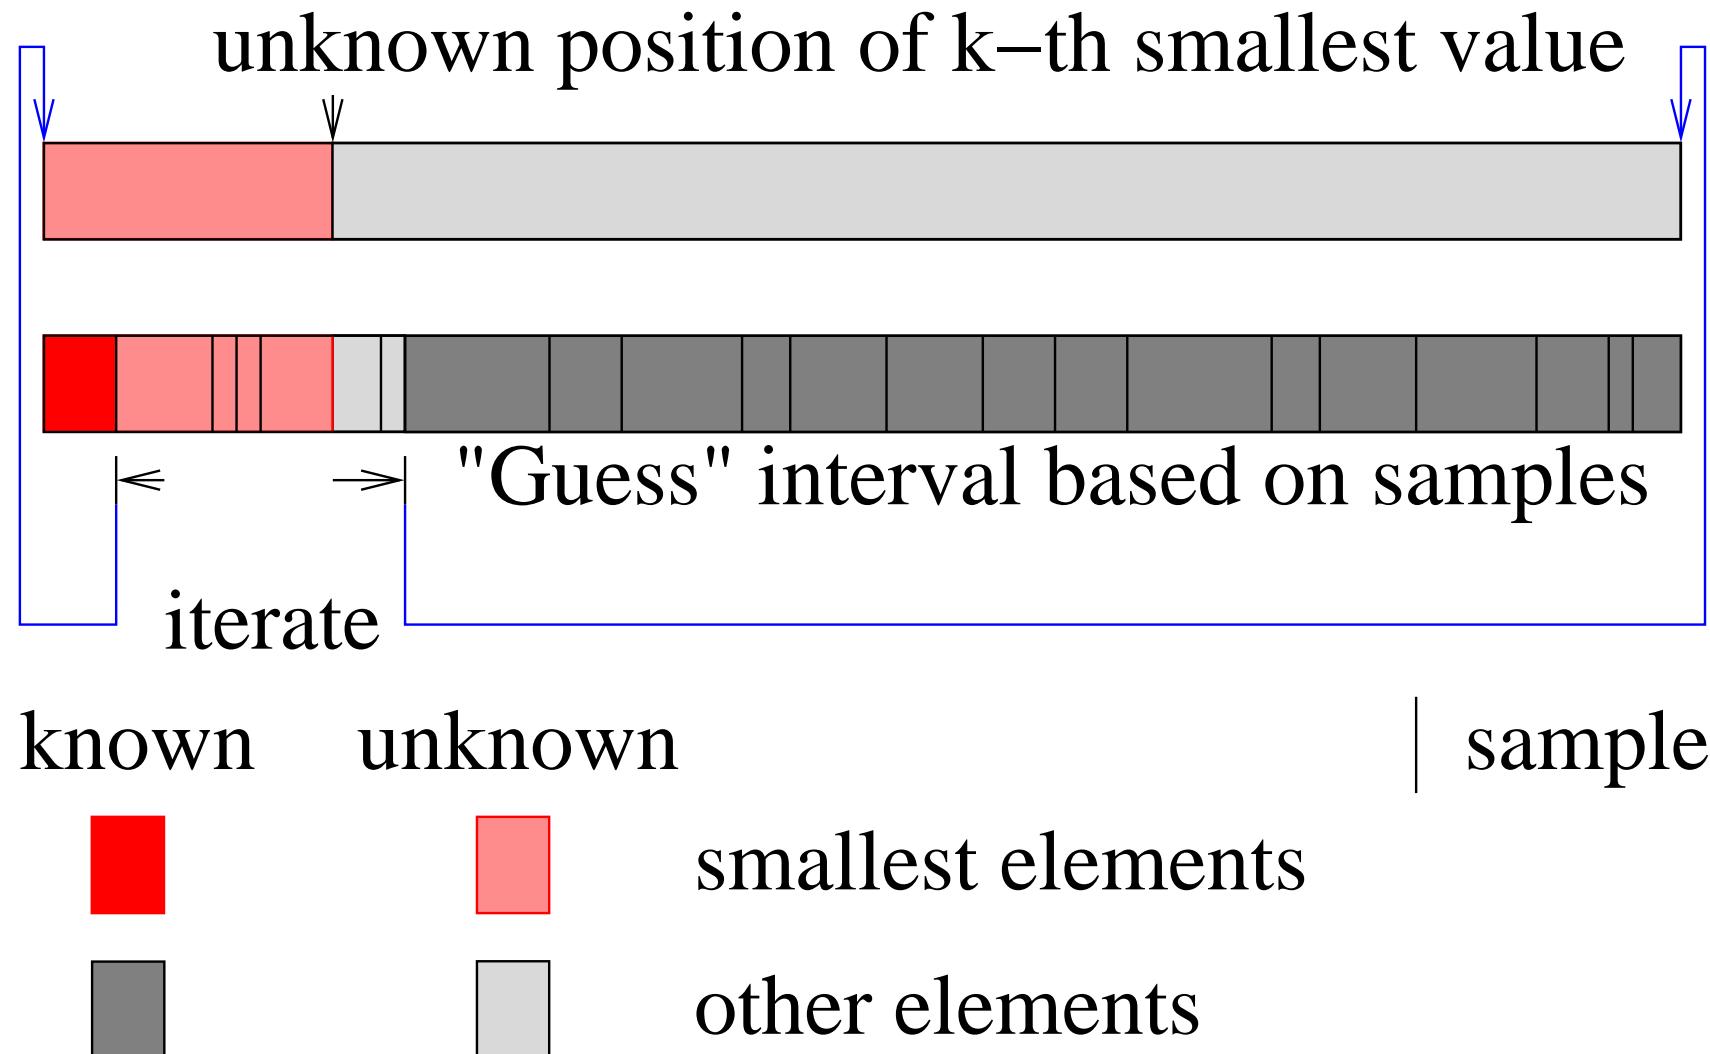
deleteMin\*: erwartet  $\mathcal{O}\left(T_{\text{coll}} + \log \frac{n}{p}\right)$

# Randomisierte Selektion [Blum et al. 1972]

Gegeben  $n$  (zufällig allozierte) Elemente  $Q$ , finde die  $k$  kleinsten.

- wähle ein sample  $s$
- $u :=$  Element mit Rang  $\frac{k}{n}|s| + \Delta$  in  $s$ .  
 $\ell :=$  Element mit Rang  $\frac{k}{n}|s| - \Delta$  in  $s$
- Partitioniere  $Q$  in
  - $Q_< := \{q \in Q : q < \ell\}$ ,
  - $Q_> := \{q \in Q : q > u\}$ ,
  - $Q' := Q \setminus Q_< \setminus Q_>$
- Falls  $|Q_<| < k$  und  $|Q_<| + |Q'| \geq k$ , gib  $Q_<$  aus und finde die  $k - |Q_<|$  kleinsten Elemente von  $Q'$
- Alle anderen Fälle unwahrscheinlich falls  $|s|, \Delta$  hinreichend groß.

# Randomisierte Selektion [Blum et al. 1972]



# Parallele Implementierung

- $|s| = \sqrt{p} \rightsquigarrow$  Sample kann in Zeit  $\mathcal{O}(T_{\text{coll}})$  sortiert werden.
- $\Delta = \Theta(p^{1/4+\varepsilon})$  für kleine Konstante  $\varepsilon$  macht die schwierigen Fälle unwahrscheinlich.
- Keine Elemente werden umverteilt. **Zufällige** Anfangsverteilung garantiert gute Lastverteilung mhw.
- mhw reichen konstant viele Iterationen bis nur noch  $\sqrt{p}$  Elemente übrig  $\rightsquigarrow$  direkt sortieren.

Insgesamt erwartete Zeit  $\mathcal{O}\left(\frac{n}{p} + T_{\text{coll}}\right)$

# Parallel Prioritätslisten, Verfeinerungen

```
Procedure deleteMin*( $Q_0, Q_1, p$ )
  while  $|\{e \in \check{Q}_0 : e < \min \check{Q}_1\}| < p$  do
     $Q_0 := Q_0 \cup \{\text{deleteMin}(Q_1)\}$           // select immediately
     $M := \text{select}(Q_0, p)$                       // später
    enumerate  $M = \{e_1, \dots, e_p\}$ 
    assign  $e_i$  to PE  $i$                             // use prefix sums
```

Or just use sufficiently many locally smallest els and check later

# Parallel Prioritätslisten, Verfeinerungen

- mergable priority queues?
- bulk delete after flush?
- Größere samples
- größere Batches löschen?
- Nur Teilmenge der PEs spielen PQ-server?

Selection by pruned merging: Eine Reduktion mit Vektorlänge

$$\mathcal{O}(\sqrt{p \log p})$$

# Asynchrone Variante

Einfügungen akzeptieren aber nicht fertig ausführen.

Batched deleteMin in einen Puffer.

Den mittels **asynchroner FIFO** zugreifen.

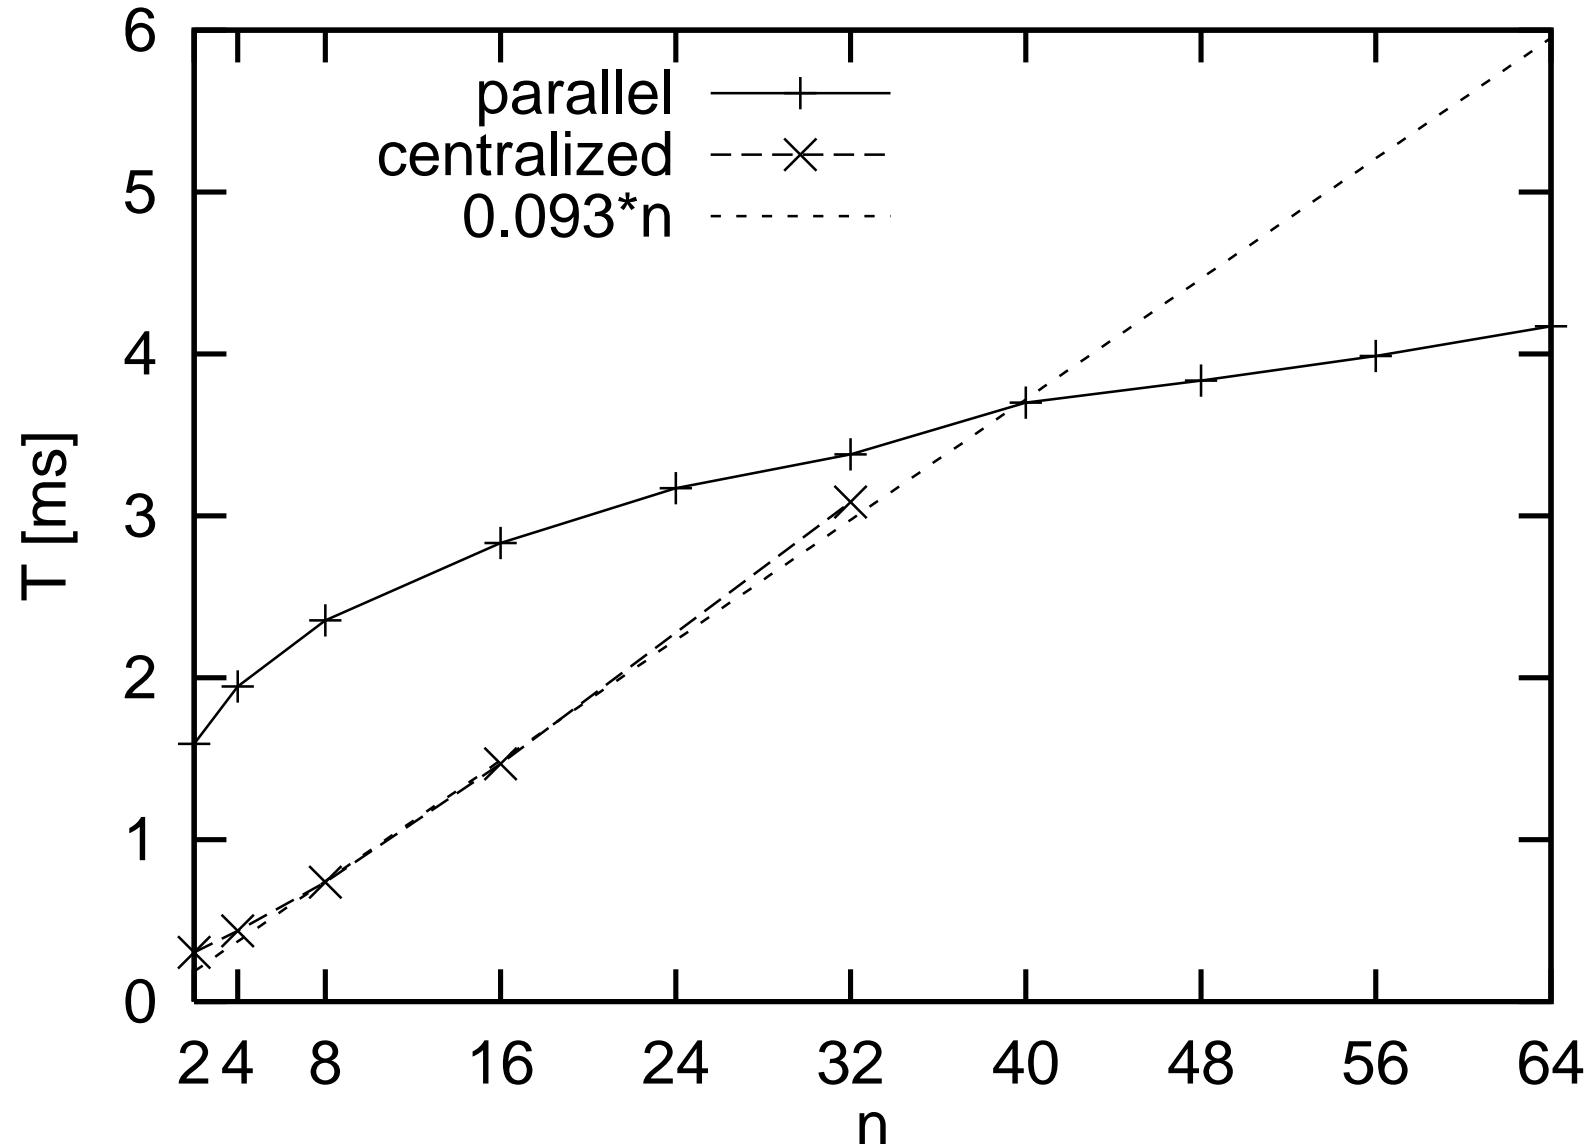
Gelegentlich:

FIFO invalidieren,

commit aller eingefügten Elemente

Puffer neu füllen

# Implementierung IBM SP-2, $m = 2^{24}$



# Implementierung Cray T3D, $m = 2^{24}$

$p = 256$

256 Els Einfügen plus deleteMin\*:

zentralisiert: > 28.16ms

parallel: 3.73ms

break-even bei 34 PEs

# Mehr zu parallelen Priority Queues

Anderer Ansatz beginnt mit binary heap:

Knoten mit  $p$  sortierten Elementen.

Invariante: Alle Elemente > alle Elemente in Elterknoten

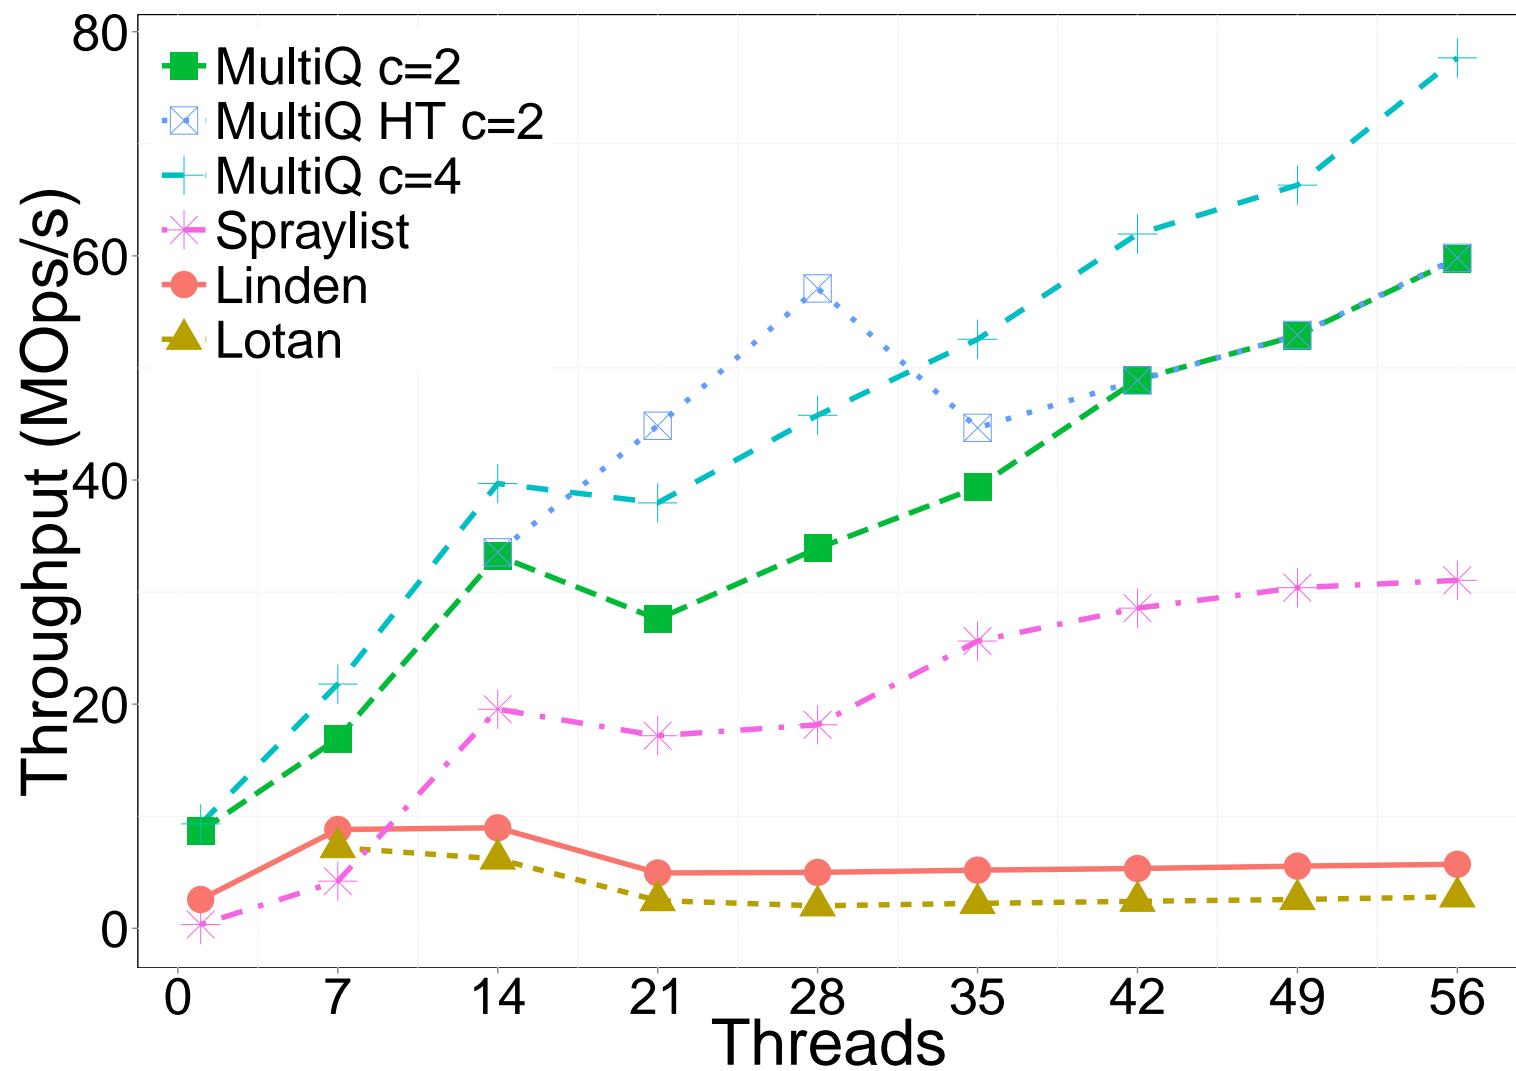
Compare-and-swap  $\rightsquigarrow$  merge-and-split

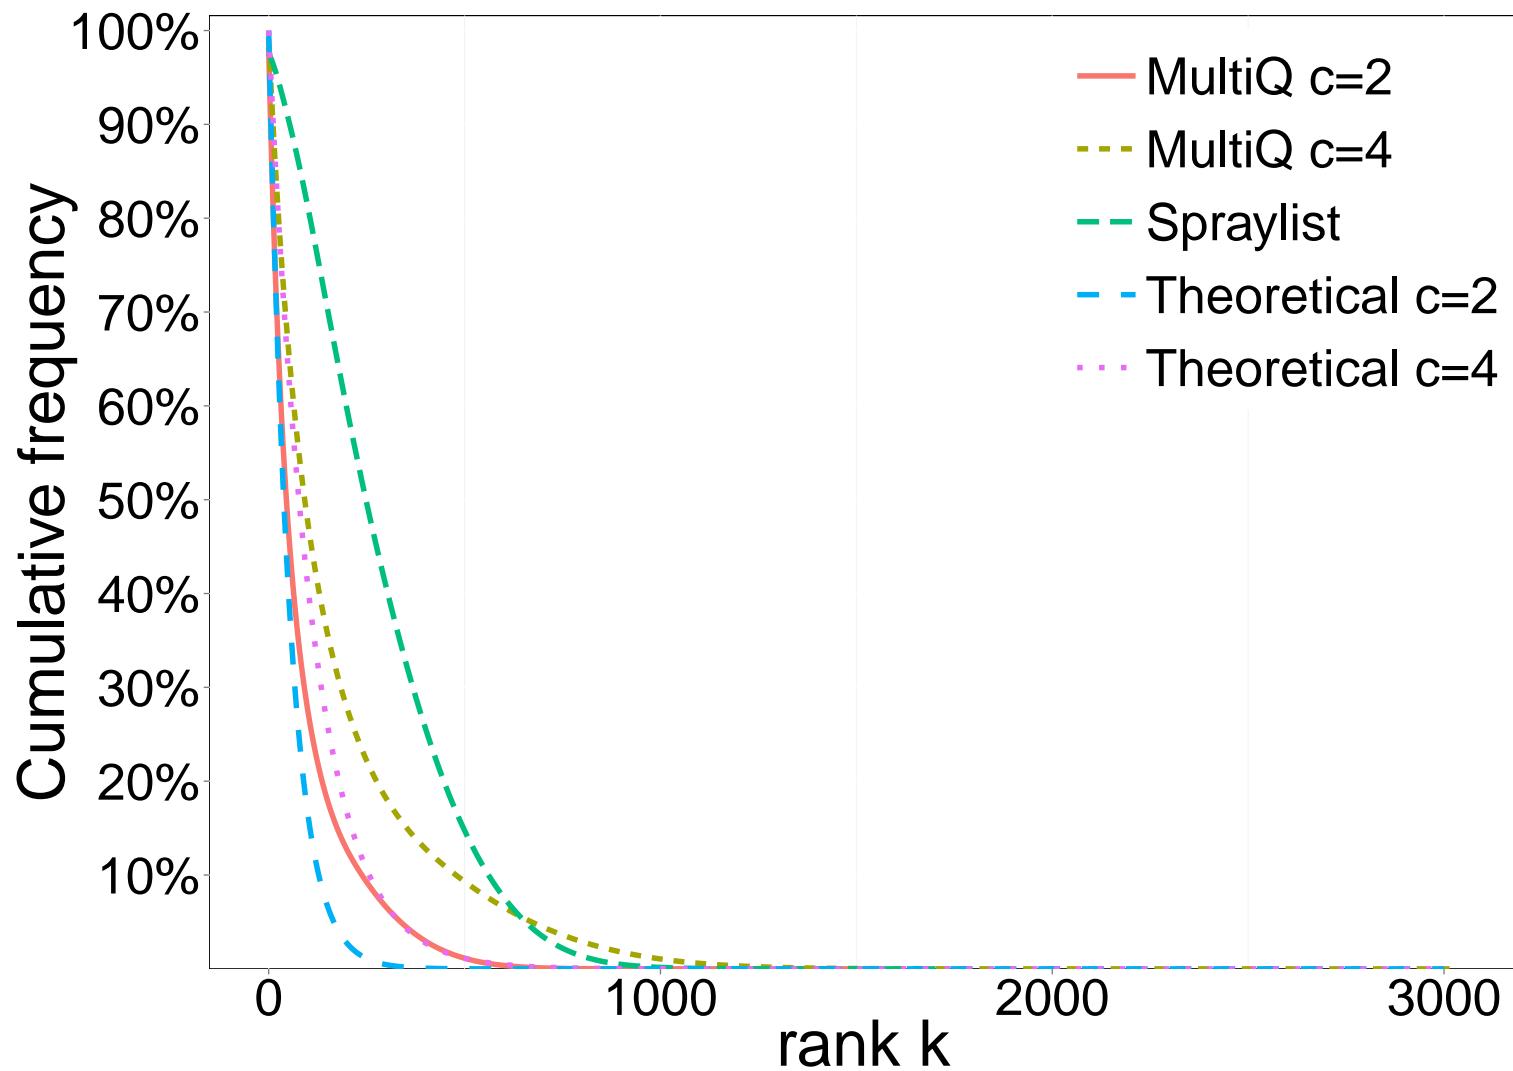
Elegant aber teuer

Parallelisierung des sequentiellen Zugriffs  $\rightsquigarrow$  konstante Zeit mit  $\log n$  Prozessoren.

# MultiQueues – simple asynchronous relaxed PQs

- $2p$  local queues  $Q[1], \dots, Q[p]$
- insert into random local queues (“wait-free” locking)
- delete smallest elements from two randomly chosen queues





# List Ranking

[JáJá Section 3.1]

## Motivation:

mit Arrays  $a[1..n]$  können wir viele Dinge **parallel** machen

- PE  $i$  bearbeitet  $a[(i - 1)\frac{n}{p} + 1..i\frac{n}{p}]$
- Prefixsummen
- ...

Können wir das gleiche mit verketteten Listen?

Ja! in Array **konvertieren**

# List Ranking

$L$ : Liste

$n$ : Elemente

$S(i)$ : Nachfolger von Element  $i$

(ungeordnet)

$S(i) = i$ : Listenende

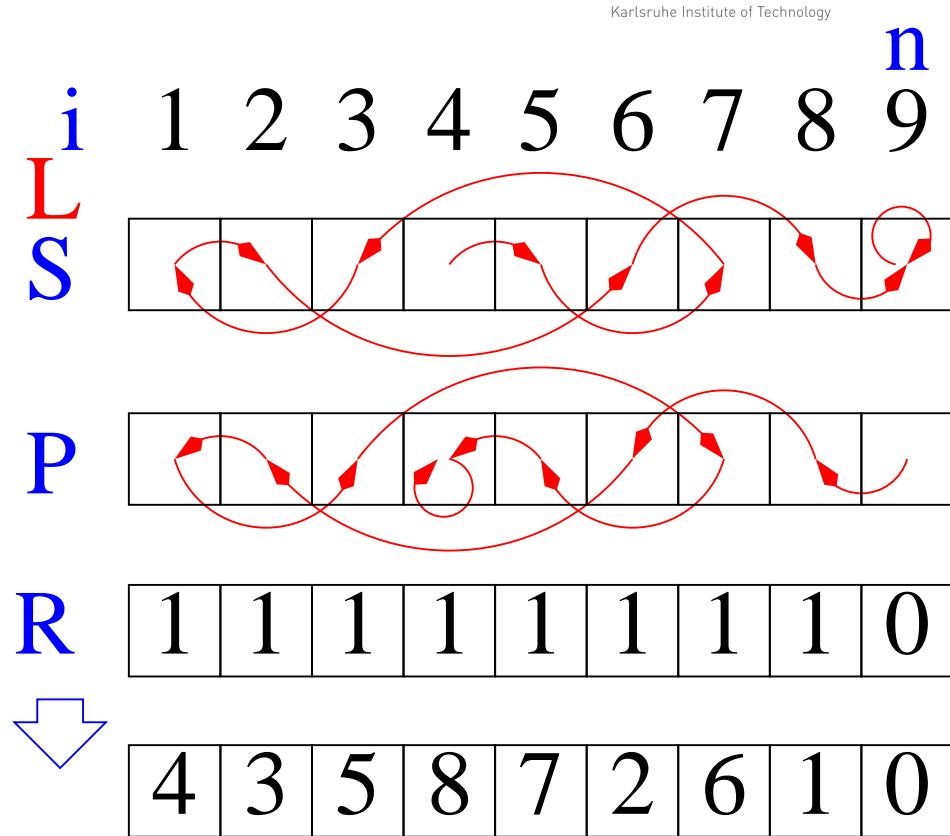
$P(i)$ : Vorgänger von Element  $i$

Übung: berechne in konstanter Zeit für  $n$  PE PRAM

$R(i)$ : Anfangs 1, 0 für letztes Element.

Ausgabe:  $R(i) = \text{Abstand von } S(i) \text{ vom Ende, rank}$

Array-Konvertierung: speichere  $S(i)$  in  $a(n - R(i))$



# Motivation II

Listen sind einfache Graphen

- ~~> warmup für Graphenalgorithmen
- ~~> lange Pfade sind ein Parallelisierungshindernis

# Pointer Chasing

```
find  $i$  such that  $S(i) = i$                                 // parallelizable
for  $r := 0$  to  $n - 1$  do
     $R(i) := r$ 
     $i := P(i)$                                          // inherently sequential?
```

- Work  $\mathcal{O}(n)$
- Zeit  $\Theta(n)$

# Doubling using CREW PRAM, $n = p$

$Q(i) := S(i)$  // SPMD. PE index  $i$

**invariant**  $\sum_{j \in Q_i} R(j) = \text{rank of item } i$

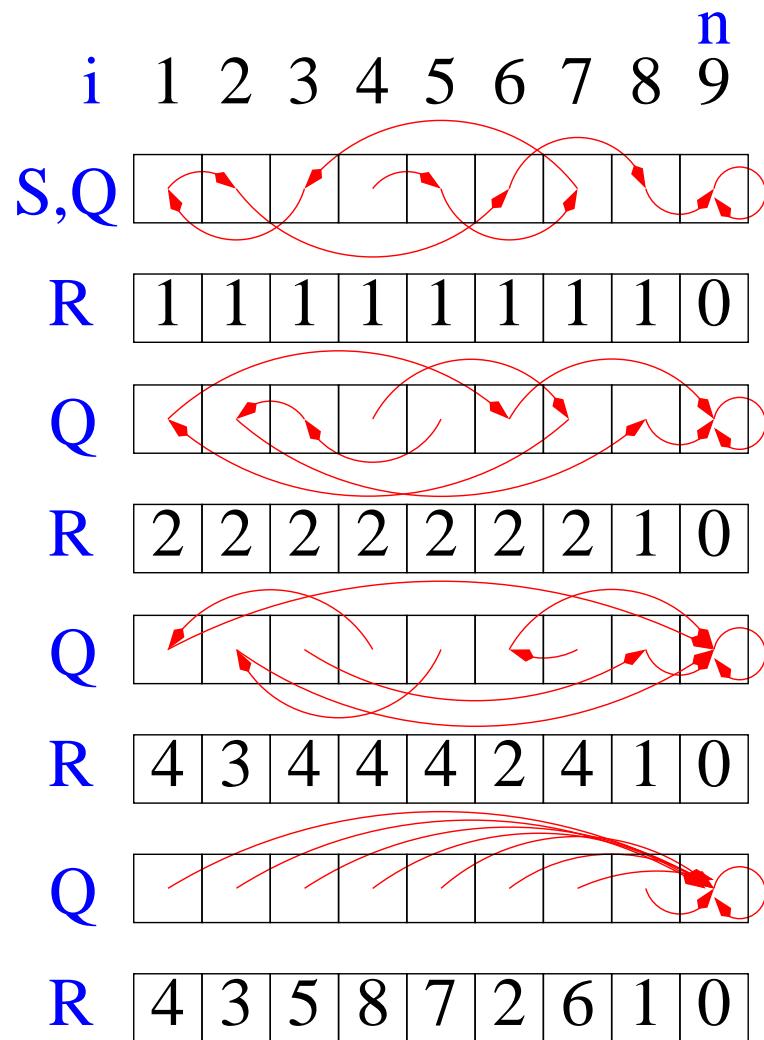
$Q_i$  is the positions given by

chasing  $Q$ -pointers from pos  $i$

**while**  $R(Q(i)) \neq 0$  **do**

$R(i) := R(i) + R(Q(i))$

$Q(i) := Q(Q(i))$



# Analyse

Induktionsannahme: Nach  $k$  Iterationen gilt

- $R(i) = 2^k$  oder
- $R(i) = \text{Endergebnis}$

Beweis: Stimmt für  $k = 0$ .

$k \rightsquigarrow k + 1$ :

Fall  $R(i) < 2^k$ : Bereits Endwert (IV)

Fall  $R(i) = 2^k, R(Q(i)) < 2^k$ : Nun Endwert (Invariante, IV)

Fall  $R(i) = R(Q(i)) = 2^k$ : Nun  $2^{k+1}$

- Work  $\Theta(n \log n)$
- Zeit  $\Theta(\log n)$

# Entfernung unabhängiger Teilmengen

//Compute the sum of the  $R(i)$ -values when following the  $S(i)$  pointers

**Procedure** independentSetRemovalRank( $n, S, P, R$ )

**if**  $p \geq n$  **then** use doubling; **return**

find  $I \subseteq 1..n$  such that  $\forall i \in I : S(i) \notin I \wedge P(i) \notin I$

find a bijective mapping  $f : \{1..n\} \setminus I \rightarrow 1..n - |I|$

**foreach**  $i \notin I$  **dopar** // remove independent set  $I$

$S'(f(i)) :=$  **if**  $S(i) \in I$  **then**  $f(S(S(i)))$  **else**  $f(S(i))$

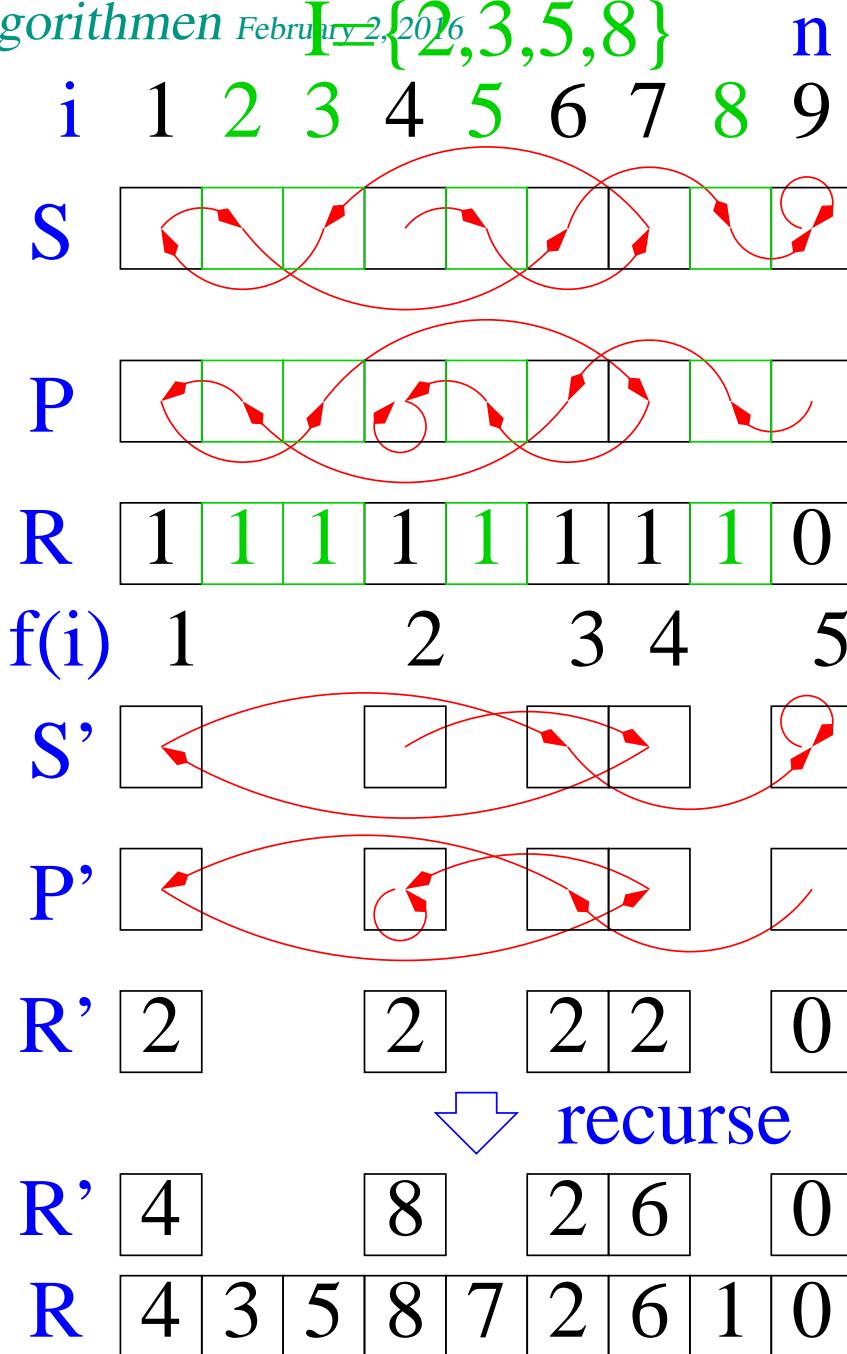
$P'(f(i)) :=$  **if**  $P(i) \in I$  **then**  $f(P(P(i)))$  **else**  $f(P(i))$

$R'(f(i)) :=$  **if**  $S(i) \in I$  **then**  $R(i) + R(S(i))$  **else**  $R(i)$

independentSetRemovalRank( $n - |I|, S', P', R'$ )

**foreach**  $i \notin I$  **dopar**  $R(i) := R'(f(i))$

**foreach**  $i \in I$  **dopar**  $R(i) := R(i) + R'(f(S(i)))$

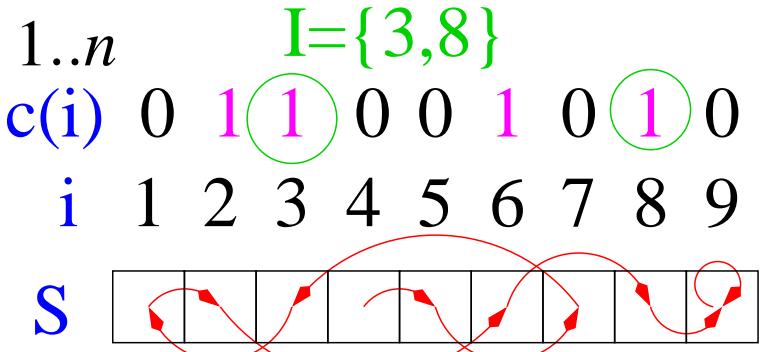


# Finden unabhängiger Teilmengen

“Werfe Münze”  $c(i) \in \{0, 1\}$  für jedes  $i \in 1..n$

$i \in I$  falls  $c(i) = 1 \wedge c(S(i)) = 0$

Erwartete Größe  $|I| \approx \frac{n}{4}$



Monte Carlo Algorithmus  $\rightsquigarrow$  Las Vegas Algorithmus:

wiederhole so lange bis  $|I| > \frac{n}{5}$ .

Erwartete Laufzeit:  $\mathcal{O}(n/p)$

Weder Anfang noch Ende der Liste sind in  $I$ .

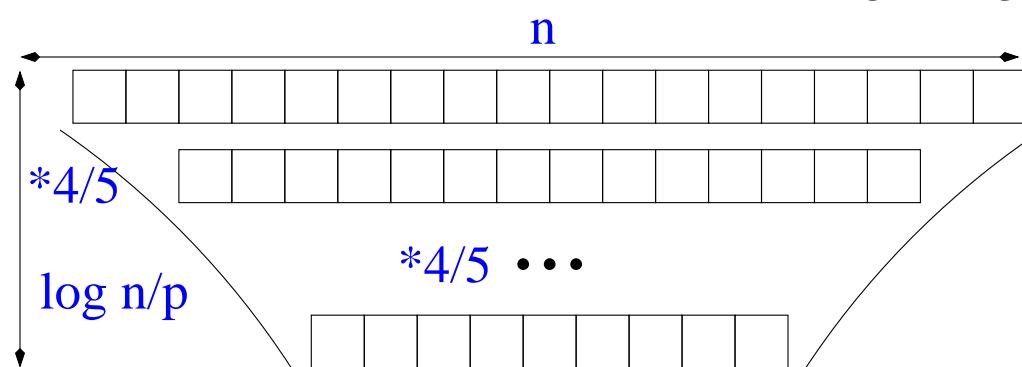
# Finden einer bijektiven Abbildung

Prefixsumme über die charakteristische Funktion von  $\{1..n\} \setminus I$ :

$$f(i) = \sum_{j \leq i} [j \notin I]$$

# Analyse

- $T(n) = \mathcal{O}\left(\frac{n}{p} + \log p\right) + T\left(\frac{4}{5}n\right)$  erwartet
- $\mathcal{O}\left(\log \frac{n}{p}\right)$  Rekursionsebenen
- Summe:  $\mathcal{O}\left(\frac{n}{p} + \log \frac{n}{p} \log p\right)$  geometrische Summe
- Lineare Arbeit, Zeit  $\mathcal{O}(\log n \log \log n)$  mit  $\frac{n}{\log n \log \log n}$  PEs



# Mehr zu List Ranking

- Einfacher Algorithmus mit erwarteter Zeit  $\mathcal{O}(\log n)$
- Komplizierter Algorithmus mit worst case Zeit  $\mathcal{O}(\log n)$
- viele “Anwendungen” in PRAM-Algorithmen
- Implementierung auf nachrichtengekoppelten Parallelrechnern  
[Sibeyn 97]:  $p = 100$ ,  $n = 10^8$ , Speedup 30.
- Verallgemeinerungen für **segmentierte Listen, Bäume**
- Verallgemeinerungen für **allgemeine Graphen**:  
**kontrahiere** Knoten oder Kanten
- Beispiel für **Multilevel-Algorithmus**

# Neuere Implementierungsergebnisse

- Zerschneide Liste an  $s$  zufälligen Stellen
- Sequentieller Algorithmus für jede Teilliste
- Rekursive Lösung auf Instanz der Größe  $s$

Speedup  $\approx 10$  über 8-core CPU (???) [Wei JaJa 2010]

# Parallele Graphenalgorithmen

Der „Kanon“ „einfacher“ Graphprobleme:

Hauptinteresse, dünn, polylog. Ausführungszeit., effizient

- DFS
- BFS
- kürzeste Wege
  - (nonnegative SSSP  $\mathcal{O}(n)$  par. Zeit. interessant für  $m = \Omega(np)$  )  
(wie ist es mit APSP?)
- topologisches Sortieren
- + Zusammenhangskomponenten (aber nicht starker Zus.)
- + Minimale Spannbäume
- + Graphpartitionierung

# Minimum Spanning Trees

[teilweise in JáJá Abschnitt 5.2]

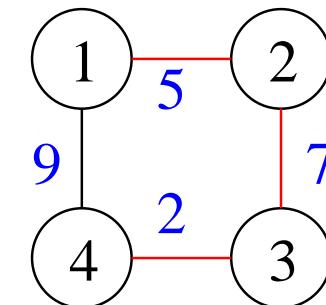
undirected Graph  $G = (V, E)$ .

nodes  $V$ ,  $n = |V|$ , e.g.,  $V = \{1, \dots, n\}$

edges  $e \in E$ ,  $m = |E|$ , two-element subsets of  $V$ .

edge weight  $c(e)$ ,  $c(e) \in \mathbb{R}_+$  wlog all different.

$G$  is connected, i.e.,  $\exists$  path between any two nodes.



Find a tree  $(V, T)$  with minimum weight  $\sum_{e \in T} c(e)$  that connects all nodes.

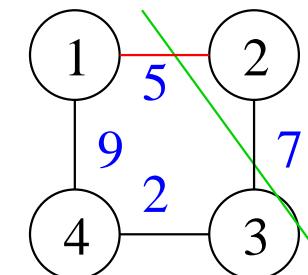
# Selecting and Discarding MST Edges

## The Cut Property

For any  $S \subset V$  consider the cut edges

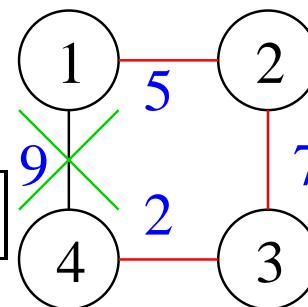
$$C = \{\{u, v\} \in E : u \in S, v \in V \setminus S\}$$

The **lightest** edge in  $C$  can be used in an MST.



## The Cycle Property

The **heaviest** edge on a cycle is not needed for an MST



# The Jarník-Prim Algorithm

[Jarník 1930, Prim 1957]

Idea: grow a tree

$T := \emptyset$

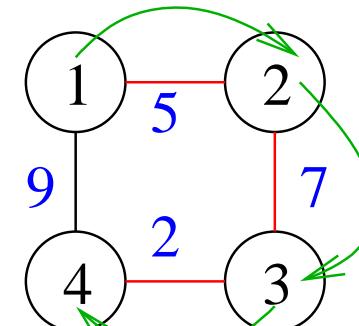
$S := \{s\}$  for arbitrary start node  $s$

**repeat**  $n - 1$  times

    find  $(u, v)$  fulfilling the **cut property** for  $S$

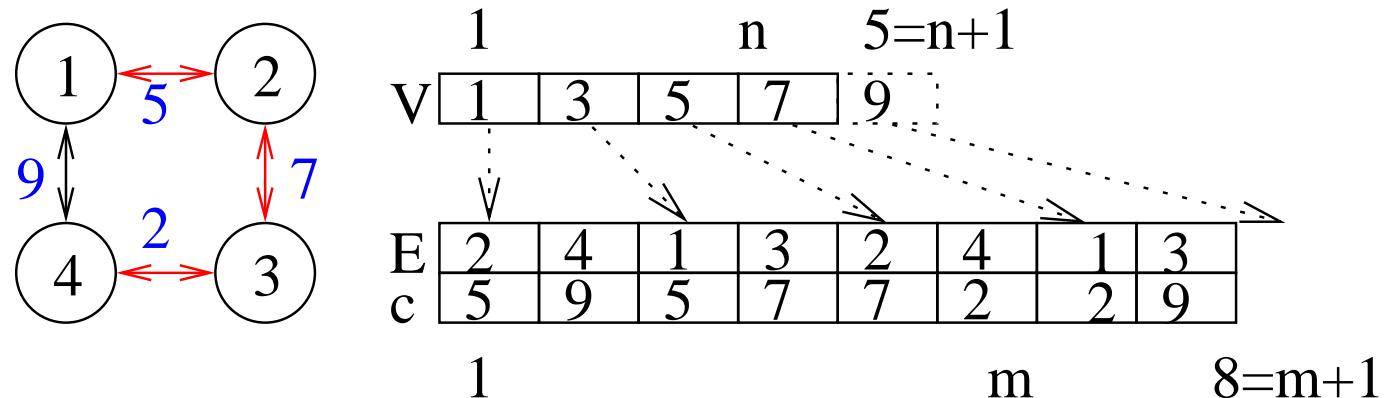
$S := S \cup \{v\}$

$T := T \cup \{(u, v)\}$



# Graph Representation for Jarník-Prim Adjacency Array

We need node → incident edges



## Analysis

- $\mathcal{O}(m + n)$  time outside priority queue
  - $n$  deleteMin (time  $\mathcal{O}(n \log n)$ )
  - $\mathcal{O}(m)$  decreaseKey (time  $\mathcal{O}(1)$  amortized)
- ⇝  $\mathcal{O}(m + n \log n)$  using Fibonacci Heaps

Problem: inherently sequential.

Best bet: use  $\log n$  procs to support  $\mathcal{O}(1)$  time PQ access.

## Kruskal's Algorithm [1956]

```
T :=  $\emptyset$                                 // subforest of the MST
foreach  $(u, v) \in E$  in ascending order of weight do
    if  $u$  and  $v$  are in different subtrees of  $T$  then
         $T := T \cup \{(u, v)\}$           // Join two subtrees
    return  $T$ 
```

## Analysis

$\mathcal{O}(\text{sort}(m) + m\alpha(m, n)) = \mathcal{O}(m \log m)$  where  $\alpha$  is the inverse Ackermann function

Problem: still sequential

Best bet: parallelize **sorting**

Idea: grow tree more aggressively

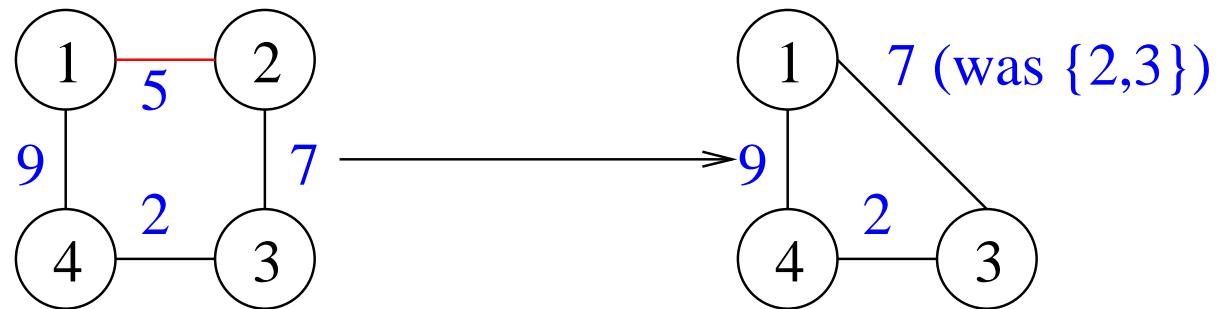
# Edge Contraction

Let  $\{u, v\}$  denote an MST edge.

Eliminate  $v$ :

**forall**  $(w, v) \in E$  **do**

$E := E \setminus (w, v) \cup \{(w, u)\}$  // but remember original terminals



## Boruvka's Algorithm

[Boruvka 26, Sollin 65]

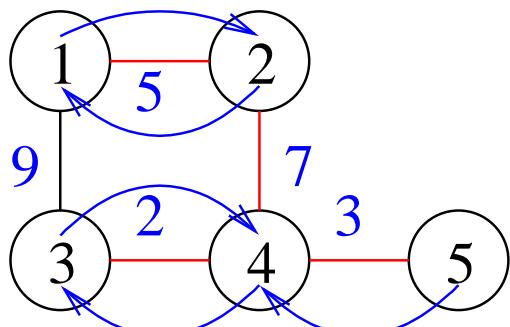
For each node find the **lightest** incident edge.

Include them into the MST (cut property)

**contract** these edges,

Time  $\mathcal{O}(m)$  per iteration

At least **halves** the number of **remaining nodes**



# Analysis (Sequential)

$\mathcal{O}(m \log n)$  time

asymptotics is OK for sparse graphs

Goal:  $\mathcal{O}(m \log n)$  work  $\mathcal{O}(\text{Polylog}(m))$  time parallelization

# Finding lightest incident edges

Assume the input is given in **adjacency array** representation

**forall**  $v \in V$  **dopar**

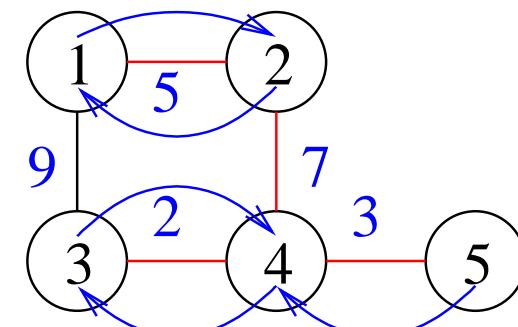
allocate  $|\Gamma(v)| \frac{p}{2m}$  processors to node  $v$  // prefix sum

find  $w$  such that  $c(v, w)$  is minimized among  $\Gamma(v)$  // reduction

output **original** edge corresponding to  $(v, w)$

**pred**( $v$ ) :=  $w$

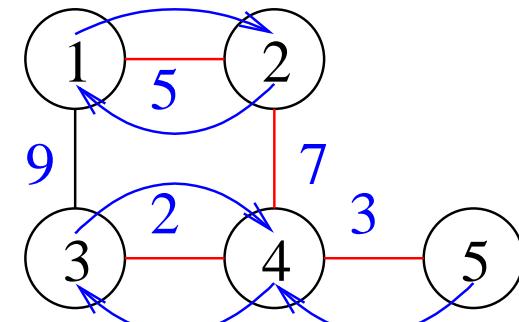
Time  $\mathcal{O}\left(\frac{m}{p} + \log p\right)$



# Structure of Resulting Components

Consider a component  $C$  of the graph  $(V, \{(v, \text{pred}(v)) : v \in V\})$

- out-degree 1
- $|C|$  edges
- pseudotree,  
i.e. a tree plus one edge
- one two-cycle at the  
lightest edge  $(u, w)$
- remaining edges lead to  $u$  or  $w$



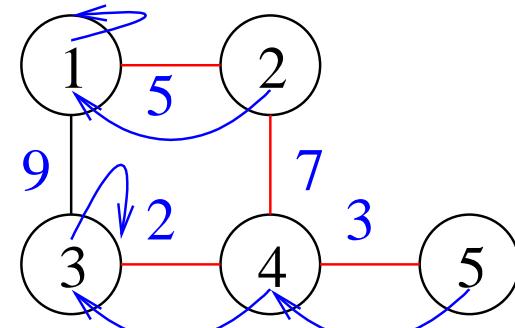
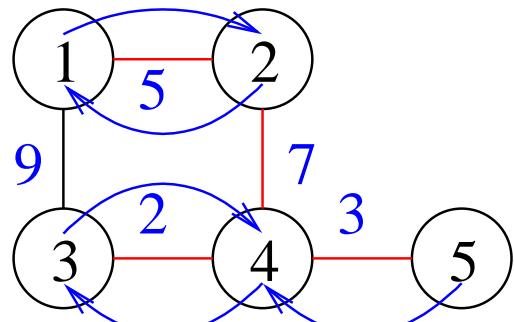
# Pseudotrees → Rooted Trees

**forall**  $v \in V$  **dopar**

$w := \text{pred}(v)$

**if**  $v < w \wedge \text{pred}(w) = v$  **then**  $\text{pred}(v) := v$

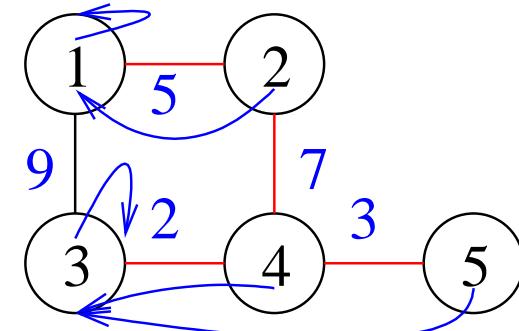
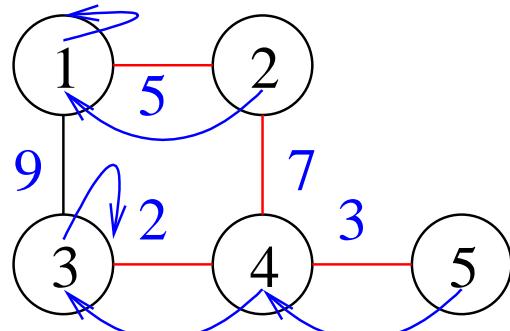
Time  $\mathcal{O}\left(\frac{n}{p}\right)$



# Rooted Trees → Rooted Stars by Doubling

```
while  $\exists v \in V : \text{pred}(\text{pred}(v)) \neq \text{pred}(v)$  do  
    forall  $v \in V$  dopar  $\text{pred}(v) := \text{pred}(\text{pred}(v))$ 
```

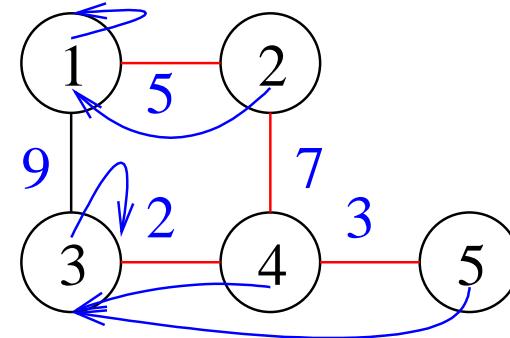
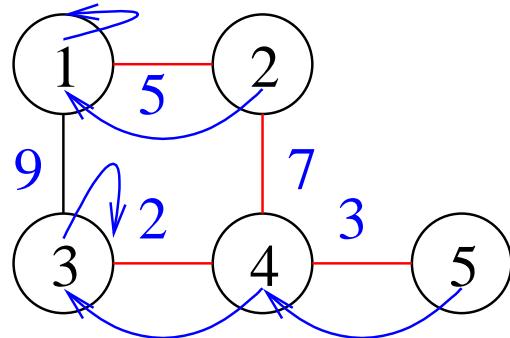
Time  $\mathcal{O}\left(\frac{n}{p} \log n\right)$



# Efficient: Rooted Trees → Rooted Stars

Time  $\mathcal{O}\left(\frac{n}{p} + \log n\right)$

Algorithm: not here. Similar ideas as in [list ranking](#)



# Contraction

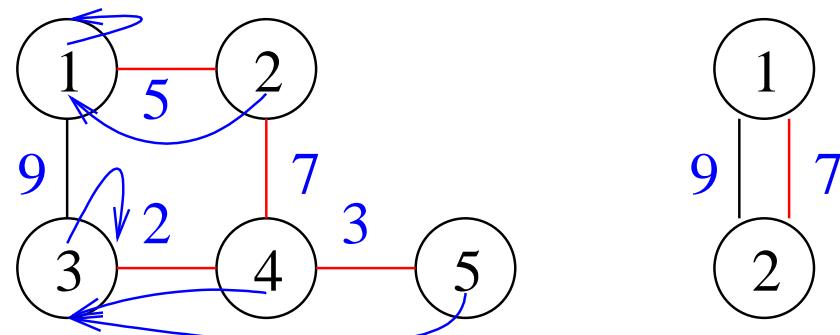
$k := \#\text{components}$

$V' = 1..k$

find a bijective mapping  $f : \text{star-roots} \rightarrow 1..k$  // prefix sum

$E' := \{(f(\text{pred}(u)), f(\text{pred}(v)), c, e_{\text{old}}) :$   
 $(u, v, c, e_{\text{old}}) \in E \wedge \text{pred}(u) \neq \text{pred}(v)\}$

Time  $\mathcal{O}\left(\frac{m}{p} + \log p\right)$



# Recursion

convert  $G' = (V', E')$  into adjacency array representation // integer sorting  
optional: remove parallel edges // retain lightest one  
recurse on  $G'$

Expected sorting time  $\mathcal{O}\left(\frac{m}{p} + \log p\right)$  CRCW PRAM  
[Rajasekaran and Reif 1989]

practical algorithms for  $m \gg p$

# Analysis

expected time bound  $T(m, n) = \mathcal{O}\left(\frac{m}{p} + \log n\right) + T(m, \frac{n}{2})$ , i.e.,

$$T(m, n) = \mathcal{O}\left(\log n\left(\frac{m}{p} + \log n\right)\right)$$

relativ effizient für  $m = \Omega(p \log^2 p)$

absolut effizient falls außerdem  $m = \mathcal{O}(n)$

# A Simpler Algorithm (Outline)

Alternate

- Find **lightest** incident edges of tree roots (grafting)
- One iteration of **doubling** (pointer jumping)
- Contract** leaves

As efficient as with more complicated “starification”

# Randomized Linear Time Algorithm

1. Factor 8 node reduction ( $3 \times$  Boruvka or sweep algorithm)

$$\mathcal{O}(m+n).$$

2.  $R \leftarrow m/2$  random edges.  $\mathcal{O}(m+n)$ .

3.  $F \leftarrow MST(R)$  [Recursively].

4. Find light edges  $L$  (edge reduction).  $\mathcal{O}(m+n)$

$$E[|L|] \leq \frac{mn/8}{m/2} = n/4.$$

5.  $T \leftarrow MST(L \cup F)$  [Recursively].

$$T(n,m) \leq T(n/8, m/2) + T(n/8, n/4) + c(n+m)$$

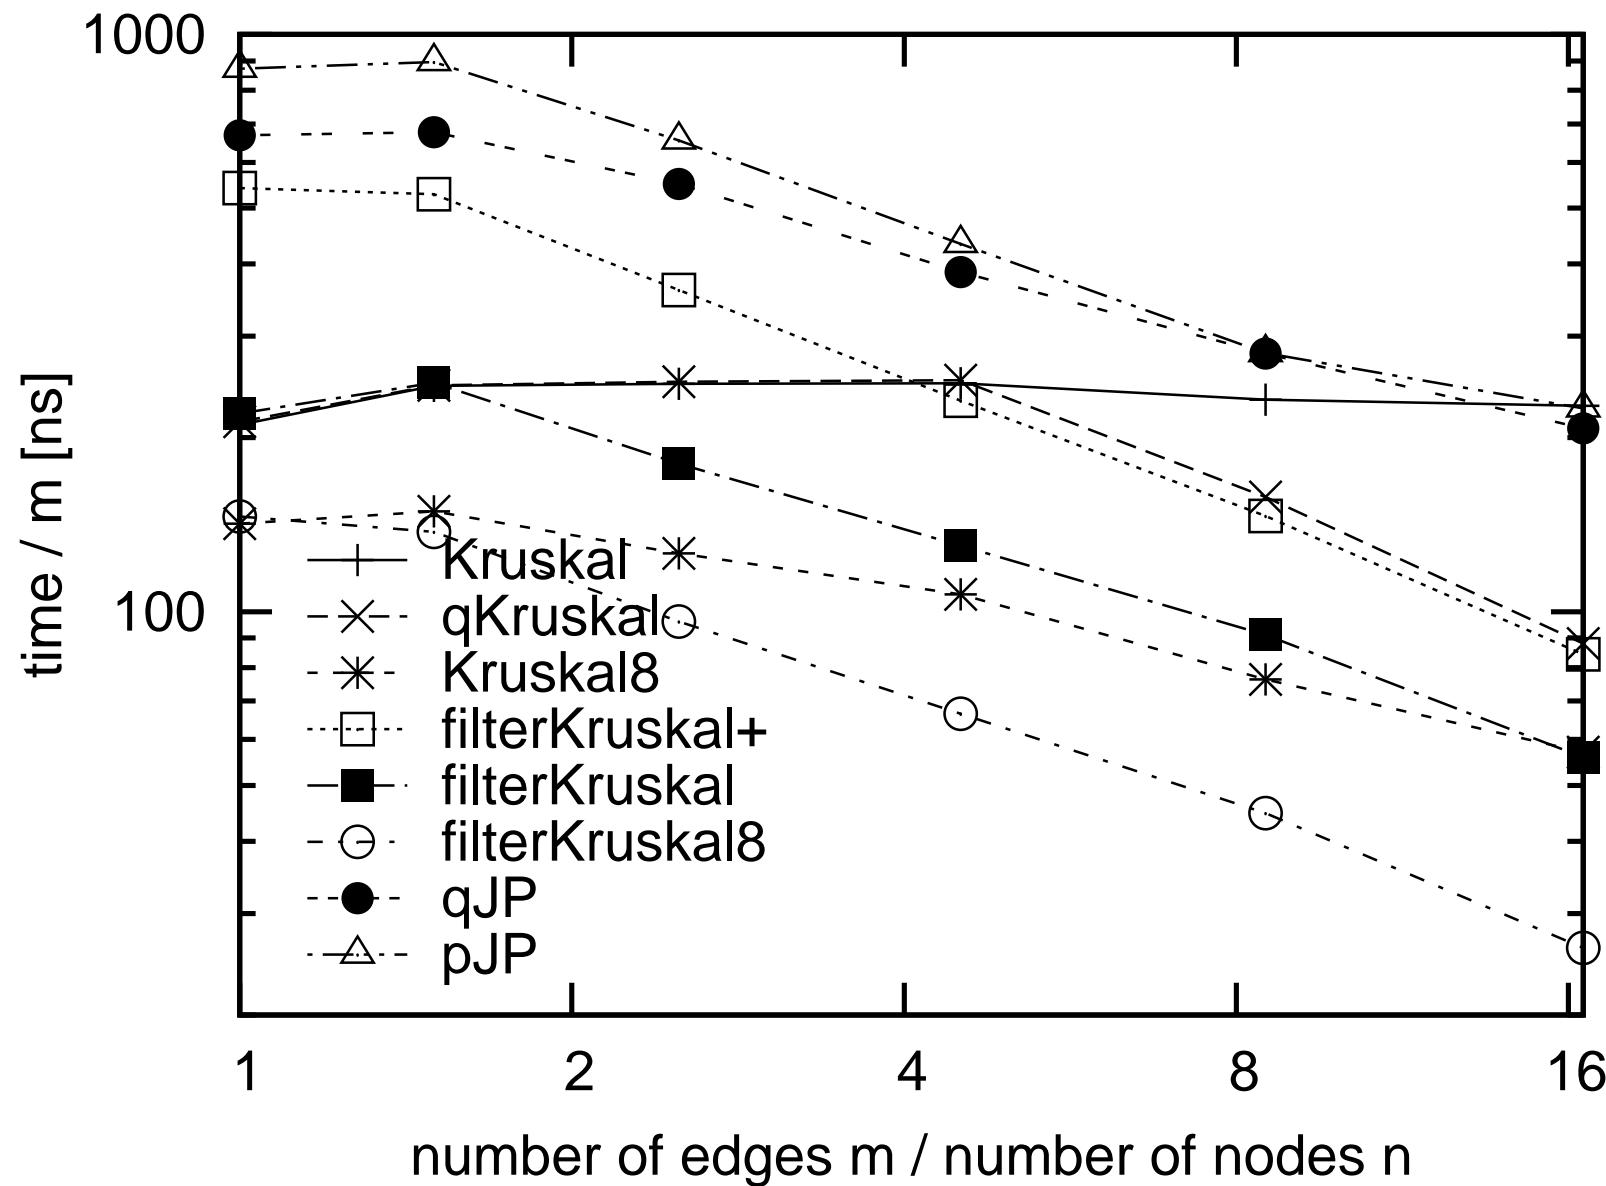
$T(n,m) \leq 2c(n+m)$  fulfills this recurrence.

# Parallel Filter Kruskal

**Procedure** filterKruskal( $E, T : \text{Sequence of Edge}, P : \text{UnionFind}$ )

```
if  $m \leq \text{kruskalThreshold}(n, m, |T|)$  then
    kruskal( $E, T, P$ )                                // parallel sort
else
    pick a pivot  $p \in E$ 
     $E_{\leq} := \langle e \in E : e \leq p \rangle$           // parallel
     $E_{>} := \langle e \in E : e > p \rangle$           // partitioning
    filterKruskal( $E_{\leq}, T, P$ )
    if  $|T| = n - 1$  then exit
     $E_{>} := \text{filter}(E_{>}, P)$                   // parallel removeIf
    filterKruskal( $E_{>}, T, P$ )
```

# Running Time: Random graph with $2^{16}$ nodes



## More on Parallel MST

[Pettie Ramachandran 02]  $\mathcal{O}(m)$  work,  $\mathcal{O}(\log n)$  expected time randomized EREW PRAM algorithm.

[Bader Cong 04] report speedup  $\approx 4$  on sparse graphs and a shared memory machine

# Lastverteilung

[Sanders Worsch 97]

Gegeben

- zu verrichtende Arbeit
- PEs

Lastverteilung = Zuordnung **Arbeit** → PEs

Ziel: minimiere parallele Ausführungszeit

# Was wir schon gesehen haben

- Lastabschätzung mittels **Sampling** sample sort
- Zuteilung ungefähr gleich grosser Stücke sample sort
- Multisequence selection balanciert multiway merging
- Dynamische Lastbalancierung für quicksort und doall
- Präfixsummen**  
quicksort, parPQ, list ranking, MSTs,...
- Parallele **Prioritätslisten** branch-and-bound

# Kostenmaß

- Maximale Last:**  $\max_{i=1}^p \sum_{j \in \text{jobs} @ \text{PE } i} T(j, i, \dots)$
- Berechnungszeit der Zuteilung
- Durchführung der Zuteilung
- Kosten einer Umverteilung
- Kommunikation zwischen Jobs? (Umfang, Lokalität?)

# Was wissen wir über die Jobs?

- genaue Größe
- ungefähre Größe
- (fast) nichts
- weiter aufspaltbar?

dito für Kommunikationskosten

# Was wissen wir über die Prozessoren?

- alle gleich?
- unterschiedlich?
- schwankende Fremdlast
- Ausfälle sind zu tolerieren?

dito für Kommunikationsfähigkeiten

# In dieser Vorlesung

## Unabhängige Jobs

- Größen genau bekannt — voll parallele Implementierung
- Größen nicht oder ungenau bekannt — zufällige Zuordnung,  
Master Worker Schema, Random Polling

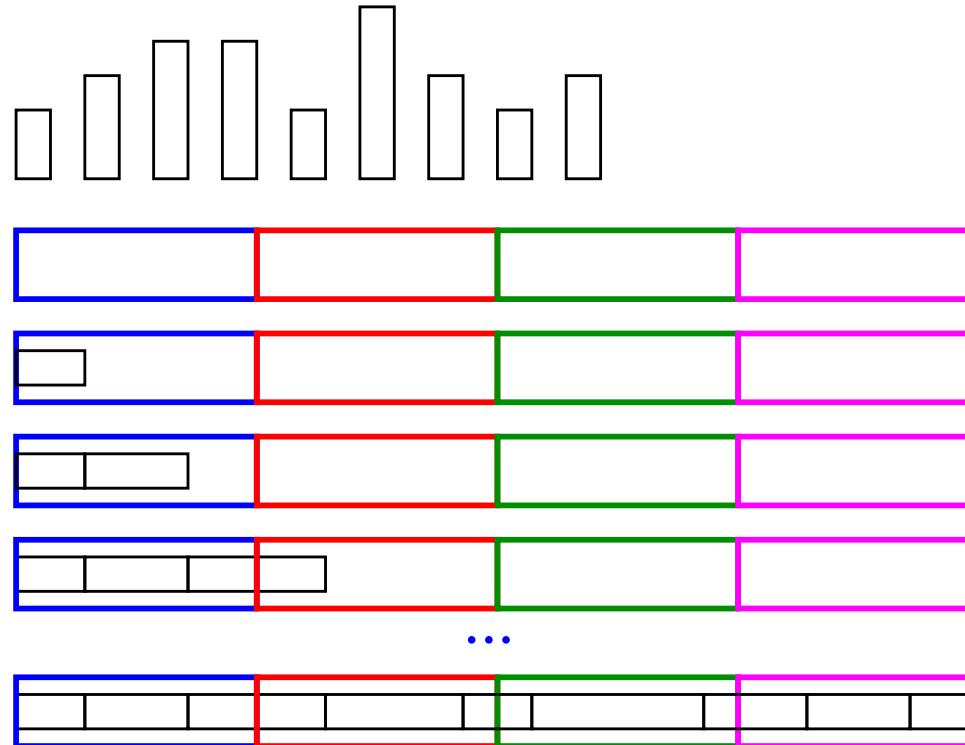
# Ein ganz einfaches Modell

- $n$  Jobs,  $\mathcal{O}(n/p)$  pro Prozessor, **unabhängig, aufspaltbar**,  
Beschreibung mit Platz  $\mathcal{O}(1)$
- Größe  $\ell_i$  genau bekannt

## Sequentielles Next Fit [McNaughton 59]

```
C :=  $\sum_{j \leq n} \frac{\ell_j}{p}$                                 // work per PE
i := 0                                         // current PE
f := C                                         // free room on PE i
j := 1                                         // current Job
l :=  $\ell_1$                                        // remaining piece of job j
while  $j \leq n$  do
    c := min(f, l)                            // largest fitting piece
    assign a piece of size c of job j to PE i
    f := f - c
    l := l - c
    if f = 0 then i++ ; f := C                // next PE
    if l = 0 then j++ ; l :=  $\ell_j$               // next job
```

## Sequentielles Next Fit [McNaughton 59]



# Parallelisierung von Next Fit (Skizze)

// Assume PE  $i$  holds jobs  $j_i..j'_i$

$$C := \sum_{j \leq n} \frac{\ell_j}{p}$$

**forall**  $j \leq n$  **dopar**

// prefix sums

$$\text{pos} := \sum_{k < i} \ell_k$$

// segmented broadcast

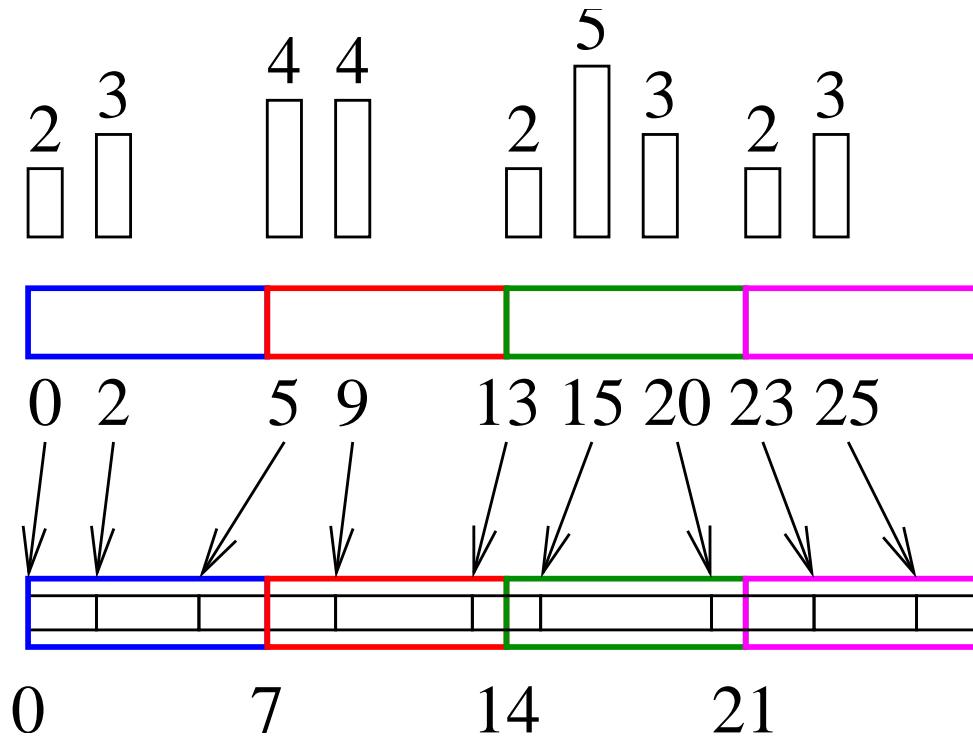
$$\text{assign job } j \text{ to PEs } \left\lfloor \frac{\text{pos}}{C} \right\rfloor .. \left\lfloor \frac{\text{pos} + \ell_j}{C} \right\rfloor$$

piece size at PE  $i = \left\lfloor \frac{\text{pos}}{C} \right\rfloor : (i+1)C - \text{pos}$

piece size at PE  $i = \left\lfloor \frac{\text{pos} + \ell_j}{C} \right\rfloor : \text{pos} + \ell_j - iC$

Zeit  $C + \mathcal{O}\left(\frac{n}{p} + \log p\right)$  falls Jobs am Anfang zufällig verteilt.

# Parallelisierung von Next Fit: Beispiel



# Atomare Jobs

assign job  $j$  to PE  $\lfloor \frac{\text{pos}}{C} \rfloor$

$$\text{Maximale Last} \leq C + \max_j \ell_j \leq 2\text{opt}$$

Bessere sequentielle Approximation:

Zuteilung nach abnehmender Jobgröße

(shortest queue, first fit, best fit) in Zeit  $\mathcal{O}(n \log n)$

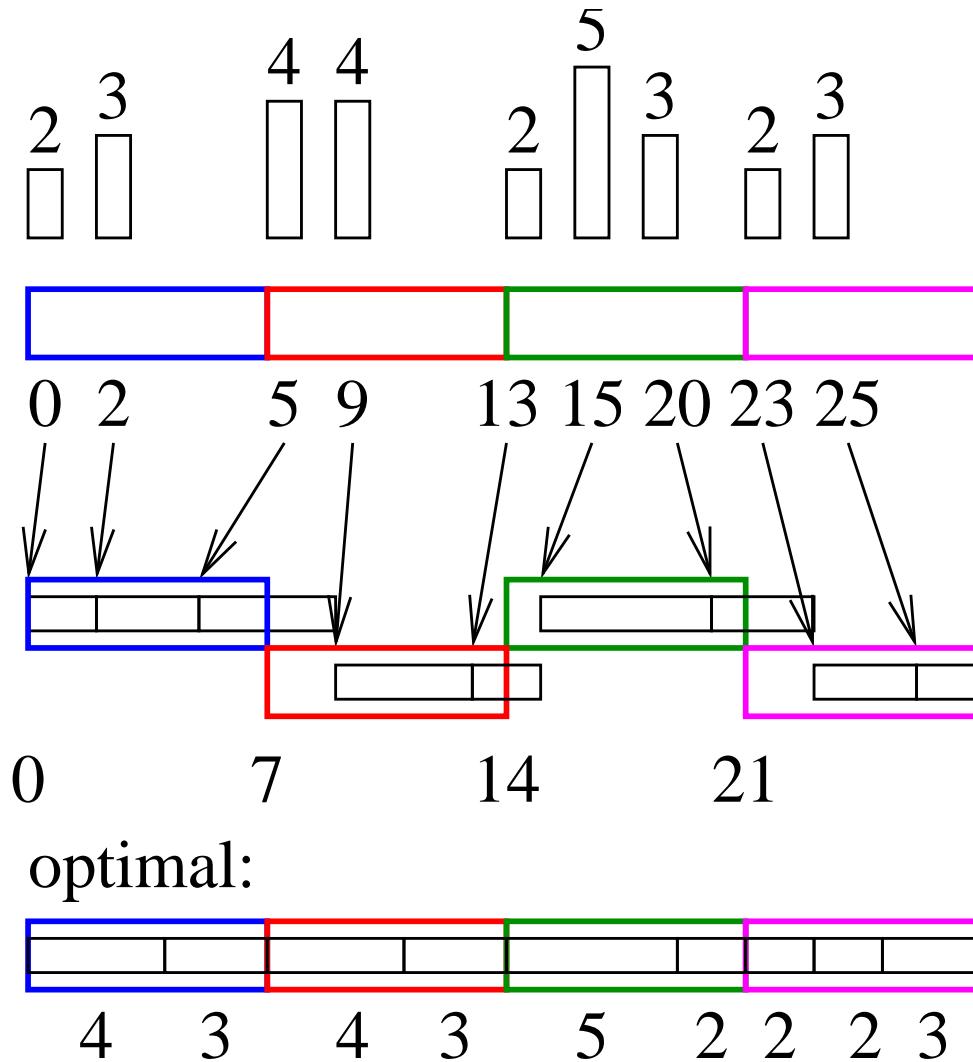
vermutlich nicht parallelisierbar

Parallel

$$\frac{11}{9} \cdot \text{opt}$$

[Anderson, Mayr, Warmuth 89]

# Atomare Jobs: Beispiel

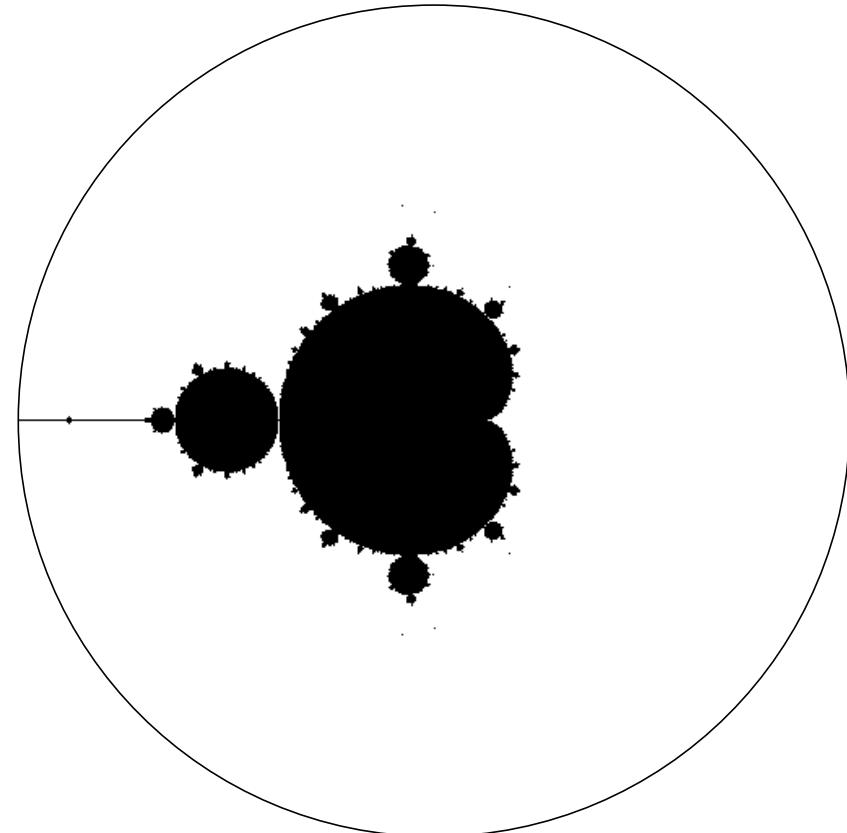


# Beispiel Mandelbrotmenge

$$z_c(m) : \mathbb{N} \rightarrow \mathbb{C}$$

$$z_c(0) := 0, \quad z_c(m+1) := z_c(m)^2 + c$$

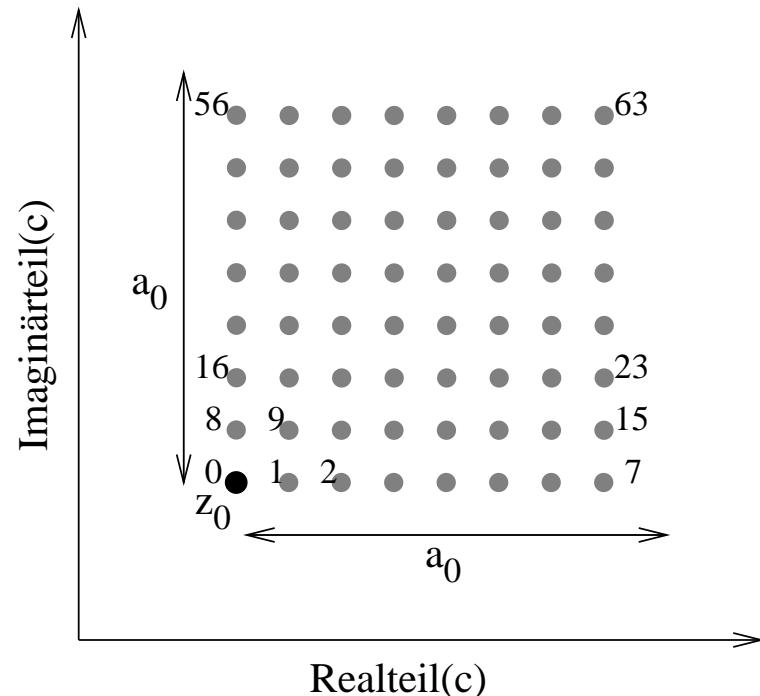
$$M := \{c \in \mathbb{C} : z_c(m) \text{ ist beschränkt}\} .$$



## Angenäherte Berechnung

- Berechnung nur für quadratischen **Ausschnitt** der komplexen Zahlenebene
- Berechnung nur für **diskretes Gitter** von Punkten
- $z_c$  unbeschränkt falls  $|z_c(k)| \geq 2$
- Abbruch nach  **$m_{\max}$**  Iterationen

Wo liegt das Lastverteilungsproblem?



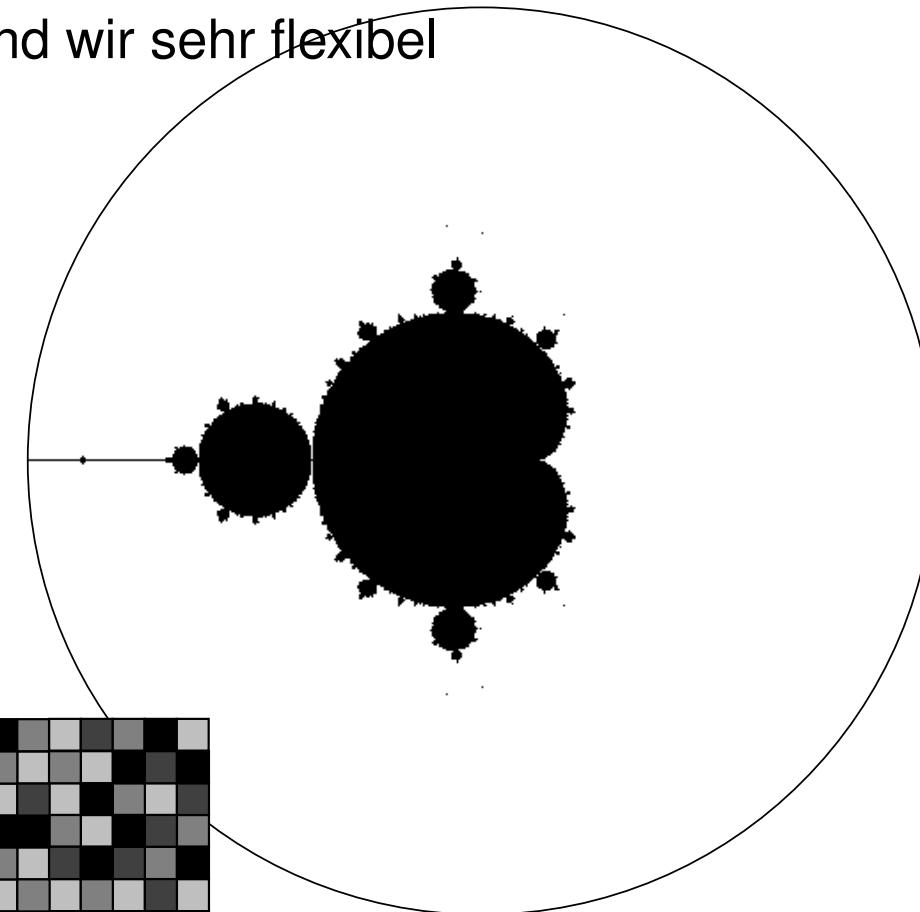
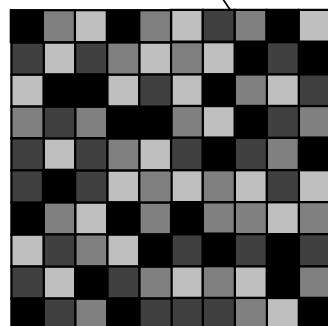
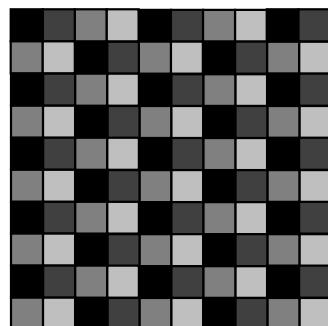
## Code

```
int iterate(int pos, int resolution, double step)
{ int iter;
  complex c =
    z0+complex((double)(pos % resolution) * step,
                (double)(pos / resolution) * step);
  complex z = c;
  for (iter = 1;
       iter < maxiter && abs(z) <= LARGE;
       iter++) {
    z = z*z + c;
  }
  return iter; }
```

## Statische Äpfelverteilung

Da kaum Kommunikation stattfindet sind wir sehr flexibel

- Streifenweise Zerlegung
  - Warum attraktiv?
  - Warum besser nicht?
- zyklisch. Gut. Aber beweisbar?
- Zufällig



Bearbeitet von:    ■ =PE 0    ■ =PE 1    ■ =PE 2    ■ =PE 3

## Parallelisierung der Zuordnungsphase

- Wenn die Teilprobleme irgendwie auf die PEs verteilt sind:  
**Zufallspermutation via all-to-all.** (Siehe auch sample sort)
- Implizites Erzeugen der Einzelteile
  - Teilproblem lässt sich allein aus seiner Nummer  $1 \dots n$  erzeugen.
  - Problem: Parallelere Berechnung einer  
**(Pseudo)Zufallspermutation**

# Pseudorandom Permutations $\pi : 0..n - 1 \rightarrow 0..n - 1$

Wlog (?) let  $n$  be a square.

- Interpret numbers from  $0..n - 1$  as **pairs** from  $\{0..\sqrt{n} - 1\}^2$ .
- $f : 0..\sqrt{n} - 1 \rightarrow 0..\sqrt{n} - 1$  (pseudo)random **function**
- Feistel permutation:  $\pi_f((a, b)) = (b, a + f(b) \bmod \sqrt{n})$   
 $(\pi_f^{-1}(b, x) = (x - f(b) \bmod \sqrt{n}, b))$
- Chain** several Feistel permutations
- $\pi(x) = \pi_f(\pi_g(\pi_h(\pi_l(x))))$  is even save in some **cryptographical** sense

# Zufälliges Zuordnen

- Gegeben:  $n$  Teilprobleme der Größe  $\ell_1, \dots, \ell_n$
- Sei  $L := \sum_{i \leq n} \ell_i$
- Sei  $l_{\max} := \max_{i \leq n} \ell_i$
- Ordne die Teilprobleme zufälligen PEs zu

Satz: Falls  $L \geq 2(\beta + 1)pl_{\max} \frac{\ln p}{\varepsilon^2} + O(1/\varepsilon^3)$

dann ist die maximale Last höchstens  $(1 + \varepsilon)\frac{L}{p}$

mit Wahrscheinlichkeit mindestens  $1 - p^{-\beta}$ . Beweis:

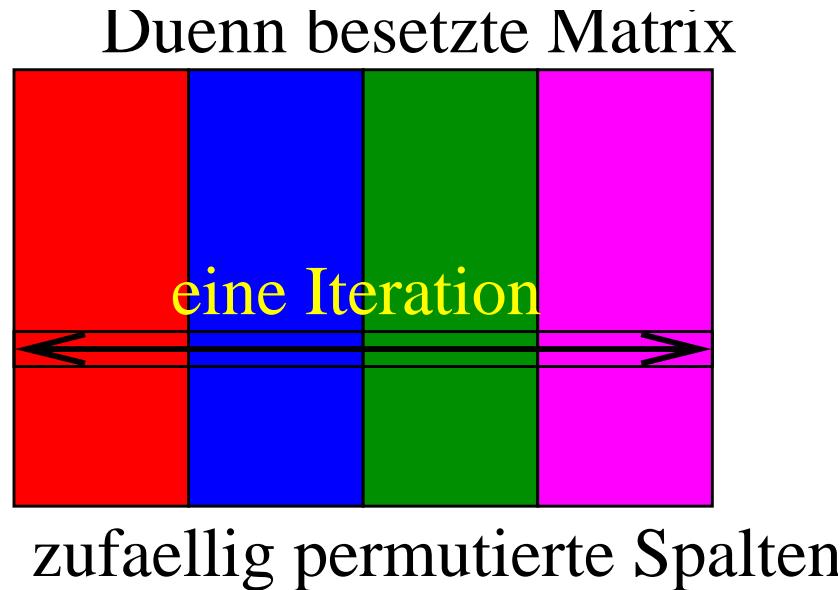
... Chernoff-Schranken...

## Diskussion

- + Teilproblemgrößen müssen überhaupt nicht bekannt sein
- + Es ist unerheblich wo die Teilprobleme herkommen  
(verteilte Erzeugung möglich)
- inakzeptabel bei großem  $l_{\max}$
- Sehr gute Lastverteilung nur bei sehr großem  $L/l_{\max}$   
(quadratisch in  $1/\varepsilon$ , logarithmisch in  $p$ ).

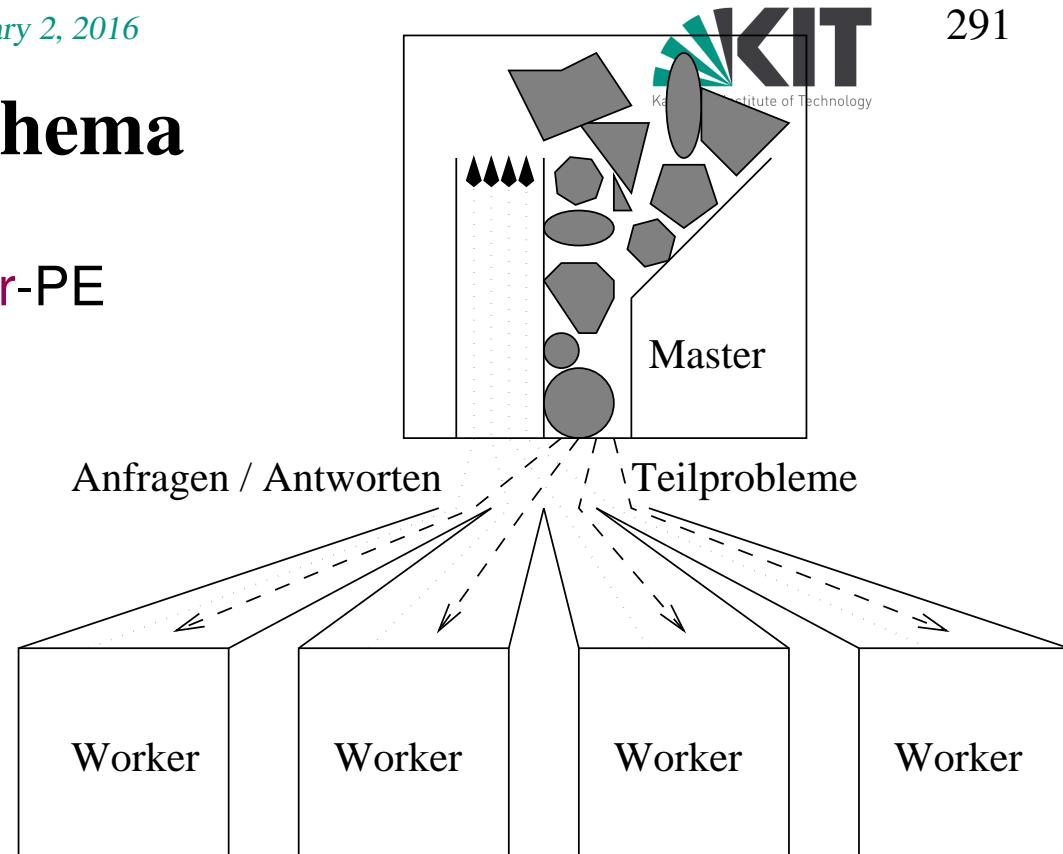
## Anwendungsbeispiel: Airline Crew Scheduling

Eine einzige zufällige Verteilung löst  $k$  simultane Lastverteilungsprobleme. (Deterministisch vermutlich ein schwieriges Problem.)



# Das Master-Worker-Schema

- Anfangs alle Jobs auf **Master-PE**
- Jobgrößen** sind **abschätzbar** aber nicht genau bekannt
- Einmal abgegebene Jobs können nicht weiter unterteilt werden (**nichtpreemptiv**)

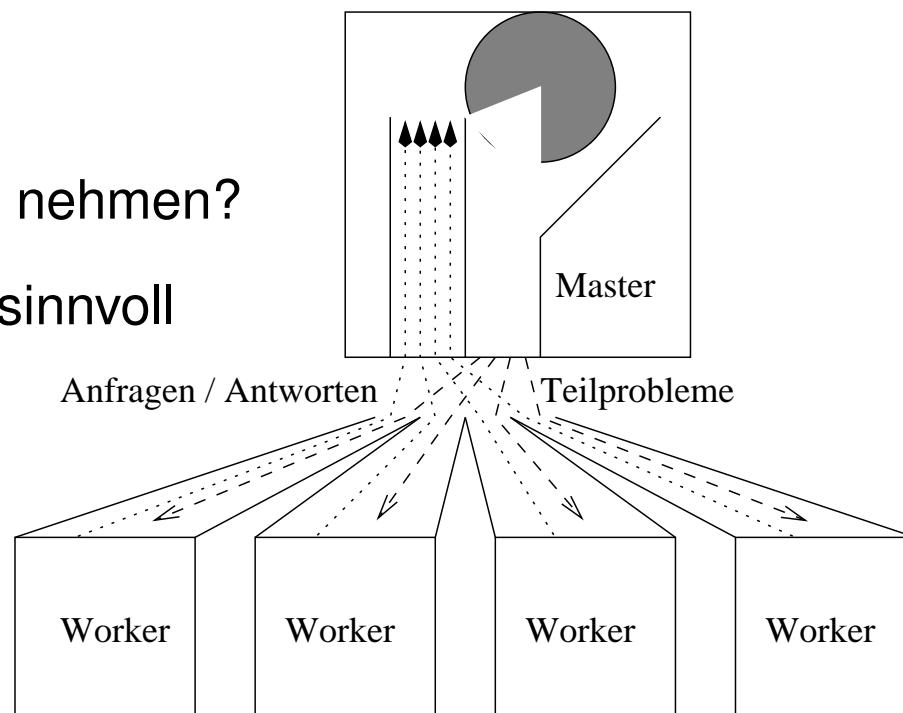


## Diskussion

- + Einfach
- + Natürliches Ein- Ausgabeschema (aber u.U. gesonderter Plattensklave)
- + Naheliegend wenn Jobgenerator nicht parallelisiert
- + Leicht zu debuggen
- Kommunikationsengpaß ⇒ Tradeoff Kommunikationsaufwand versus Imbalance
- Wie soll aufgespalten werden?
- Multilevelschemata sind kompliziert und nur begrenzt hilfreich

## Größe der Teilprobleme

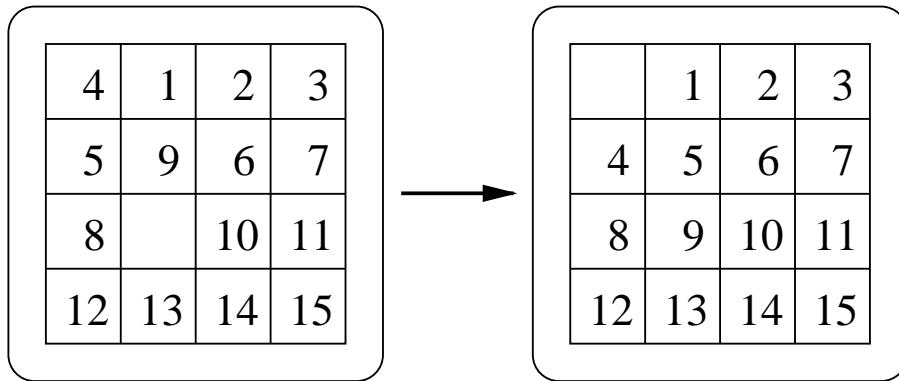
- Möglichst grosse Probleme abgeben solange Lastverteilung nicht gefährdet. Warum?
- Konservatives Kriterium: **obere** Schranke für die Größe des abgegebenen Teilproblems  $\leq$   
 $1/P$ -tel **untere** Schranke  
für Systemlast.
- Woher Größenabschätzung nehmen?
- Aggressivere Verfahren ggf. sinnvoll



# Work Stealing

- (Fast) Beliebig unterteilbare Last
- Anfangs alles auf PE 0
- Fast nichts bekannt über Teilproblemgrößen
- Preemption erlaubt. (Sukzessives aufspalten)

# Example: The 15-Puzzle

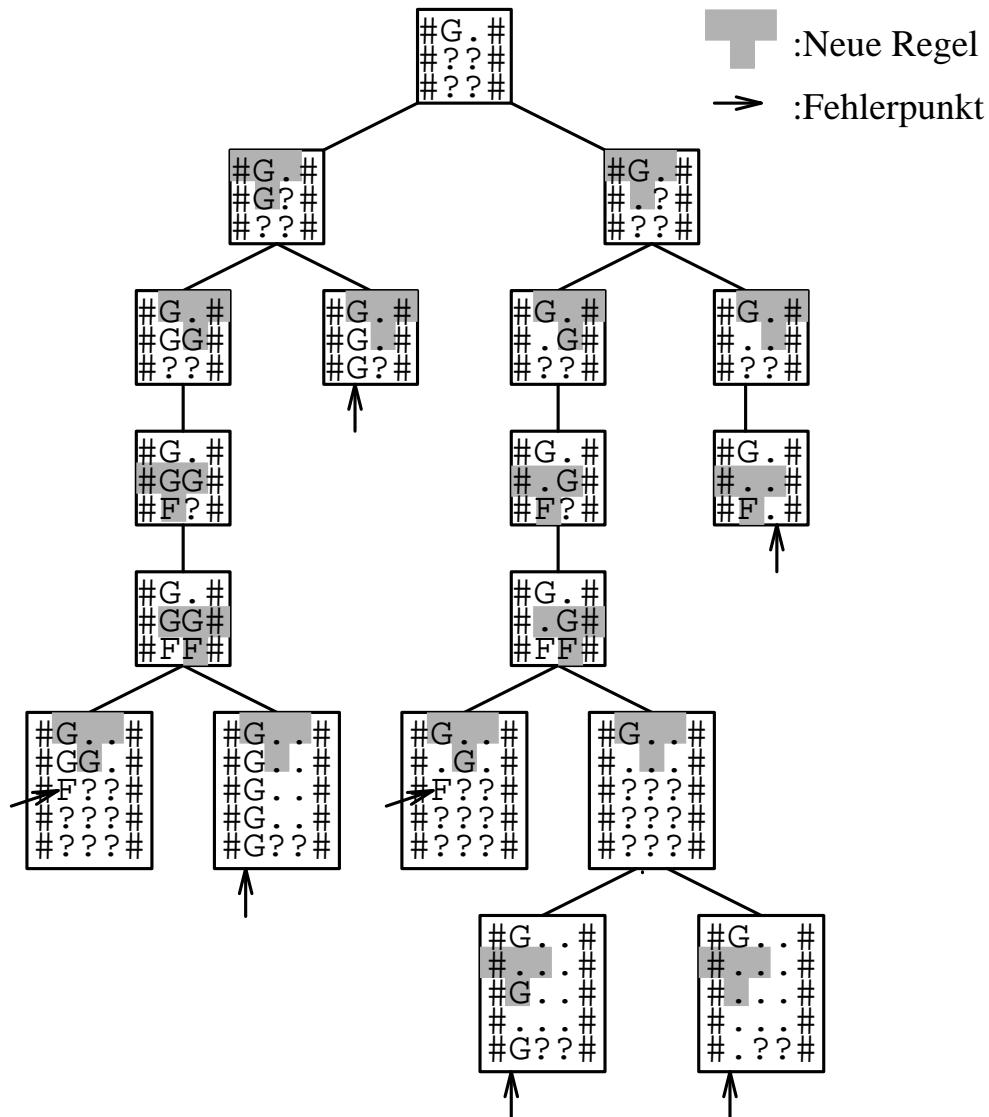


Korf 85: Iterative deepening depth first search with  $\approx 10^9$  tree nodes.

# Example: Firing Squad Synchronization Problem

```
#G.#G..#G...#G....#G.....#G.....#G.....#G.....#
#GG#GX.#GX..#GX..#GX...#GX...#GX...#GX...#GX...
#FF#XXX#XXG.#XXG..#XXG...#XXG...#XXG...#XXG...#
#GGG#GX.G#GX.X.#GX.X..#GX.X..#GX.X..#GX.X..#
#FFF#XXXX#XXG.X#XXG.G.#XXG.G..#XXG.G..#
#GGGG#GX.GX#GX.XXG#GX.XXX.#GX.XXX..#
#FFFF#XXXXX#XXG.XX#XXG.G.X#XXG.G.G.#
#GGGGG#GX.G.G#GX.XXGX#GX.XXXXG#
#FFFFFF#XXXXXX#XXG.XGX#XXG.GGXX#
#GGGGGG#GX.G.GX#GX.XXGXG#
#FFFFFFF#XXXXXXXX#XXG.XGXX#
#GGGGGGGG#GX.G.GXG#
#FFFFFFF#XXXXXXXXX#XXG.XGXX#
#GGGGGGGG#GGGGGGGG#
#FFFFFFF#XXXXXXXXX#XXG.XGXX#
```

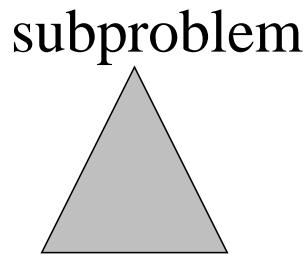
# Backtracking over Transition Functions



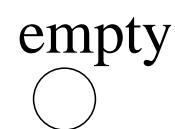
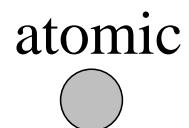
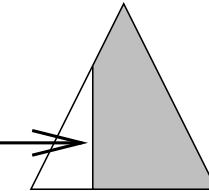
# Goal for the analysis

$$T_{\text{par}} \leq (1 + \varepsilon) \frac{T_{\text{seq}}}{p} + \text{lower order terms}$$

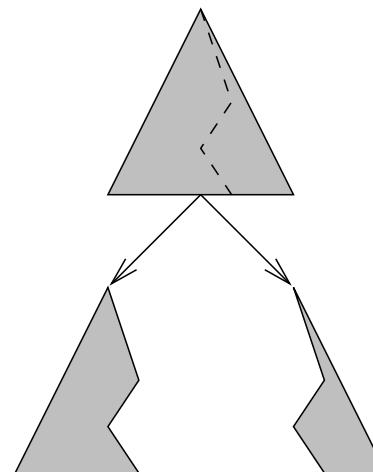
# An Abstract Model: Tree Shaped Computations



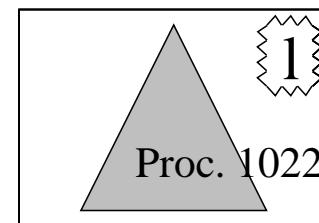
work  
sequentially



split



send



# Tree Shaped Computations: Parameters

$T_{\text{atomic}}$ : max. time for finishing up an **atomic** subproblem

$T_{\text{split}}$ : max. time needed for splitting

$h$ : max. **generation**  $\text{gen}(P)$  of a nonatomic subproblem  $P$

$\ell$ : max size of a subproblem description

$p$ : no. of processors

$T_{\text{rout}}$ : time needed for communicating a subproblem ( $T_{\text{start}} + \ell T_{\text{byte}}$ )

$T_{\text{coll}}$ : time for a reduction

# Relation to Depth First Search

let stack consist of root node only

**while** stack is not empty **do**

    remove a node  $N$  from the stack

**if**  $N$  is a leaf **then**

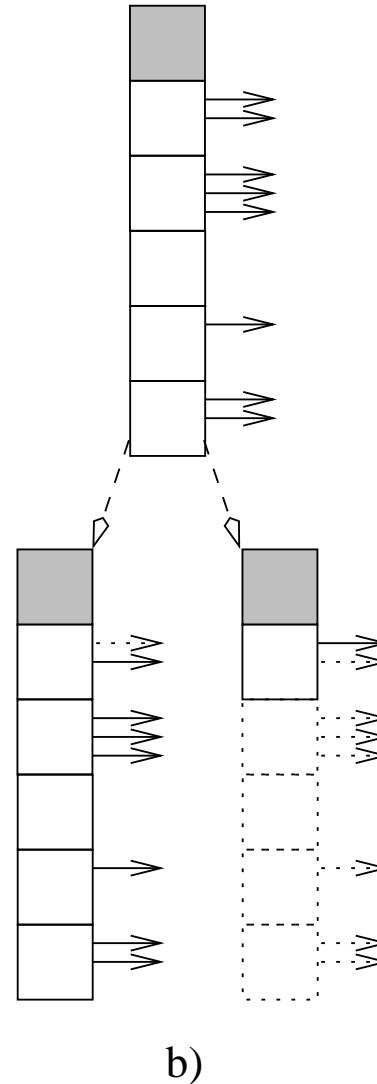
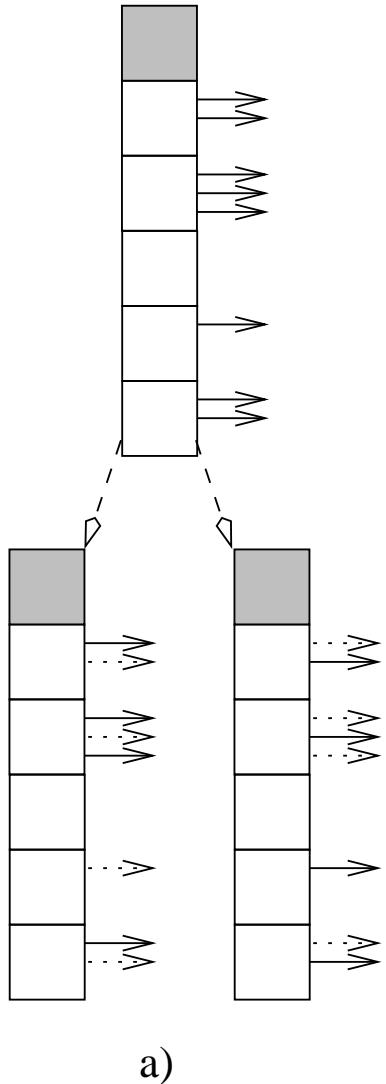
        evaluate leaf  $N$

**else**

        put successors of  $N$  on the stack

**fi**

# Splitting Stacks



# Other Problem Categories

- Loop Scheduling
- Higher Dimensional Interval Subdivision
- Particle Physics Simulation
- Generalization: Multithreaded computations.  $h \rightsquigarrow T_\infty$

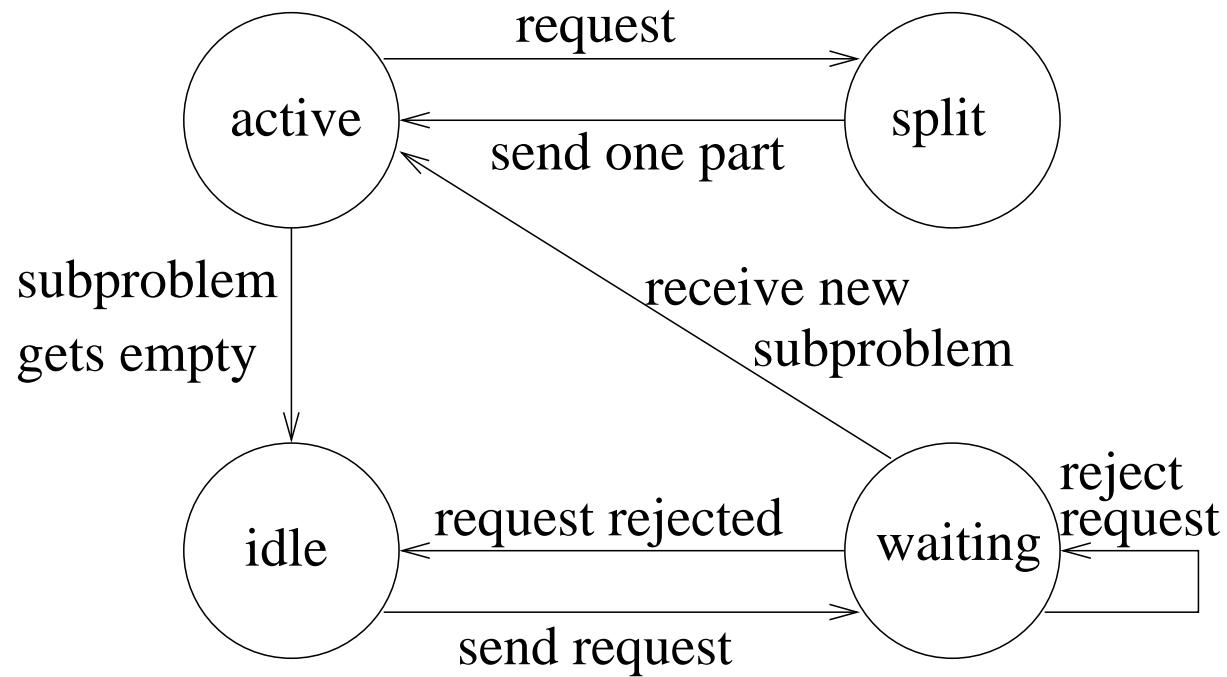
# An Application List

- Discrete Mathematics (Toys?):
  - Golomb Rulers
  - Cellular Automata, Trellis Automata
  - 15-Puzzle,  $n$ -Queens, Pentominoes ...
- NP-complete Problems (nondeterminism  $\rightsquigarrow$  branching)
  - 0/1 Knapsack Problem (fast!)
  - Quadratic Assignment Problem
  - SAT
- Functional, Logical Programming Languages
- Constraint Satisfaction, Planning, ...
- Numerical: Adaptive Integration, Nonlinear Optimization by Interval Arithmetics, Eigenvalues of Tridiagonal Matrices

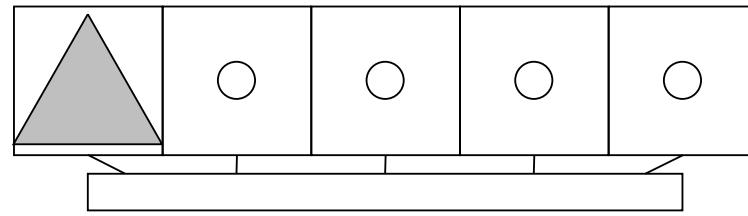
# Limits of the Model

- Quicksort and similar divide-and-conquer algorithms (shared memory OK ↽ Cilk, MCSTL, Intel TBB, OpenMP 3.0?)
- Finding the first Solution (often OK)
- Branch-and-bound
  - Verifying bounds OK
  - Depth-first often OK
- Subtree dependent pruning
  - FSSP OK
  - Game tree search tough (load balancing OK)

# Receiver Initiated Load Balancing

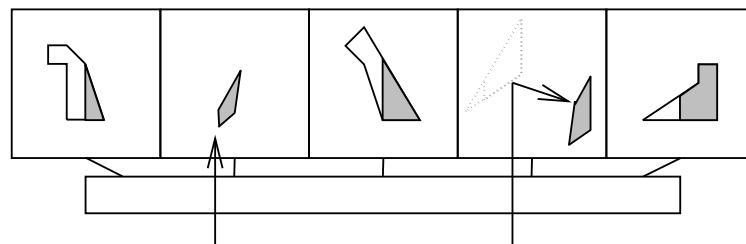
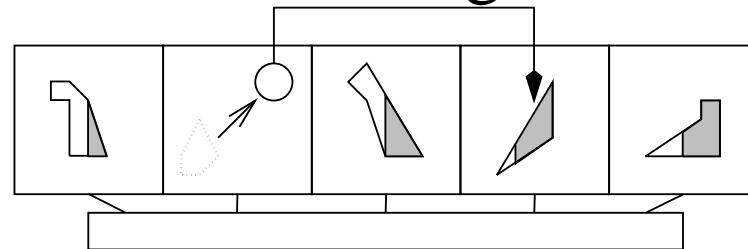


# Random Polling



⋮

Anfrage



⋮

Aufspaltung

# $\tilde{O}(\cdot)$ Calculus

$X \in \tilde{O}(f(n))$  – iff  $\forall \beta > 0 :$

$$\exists c > 0, n_0 > 0 : \forall n \geq n_0 : \mathbb{P}[X > cf(n)] \leq n^{-\beta}$$

Advantage: simple rules for sum and maximum.

# Termination Detection

not here

# Synchronous Random Polling

$P, P'$  : Subproblem

$P := \text{if } i_{\text{PE}} = 0 \text{ then } P_{\text{root}} \text{ else } P_\emptyset$

**loop**     $P := \text{work}(P, \Delta t)$

$m' := |\{i : T(P@i) = 0\}|$

**if**  $m' = p$  **then** exit loop

**else if**  $m' \geq m$  **then**

**if**  $T(P) = 0$  **then** send a request to a random PE

**if** there is an incoming request **then**

$(P, P') := \text{split}(P)$

            send  $P'$  to one of the requestors

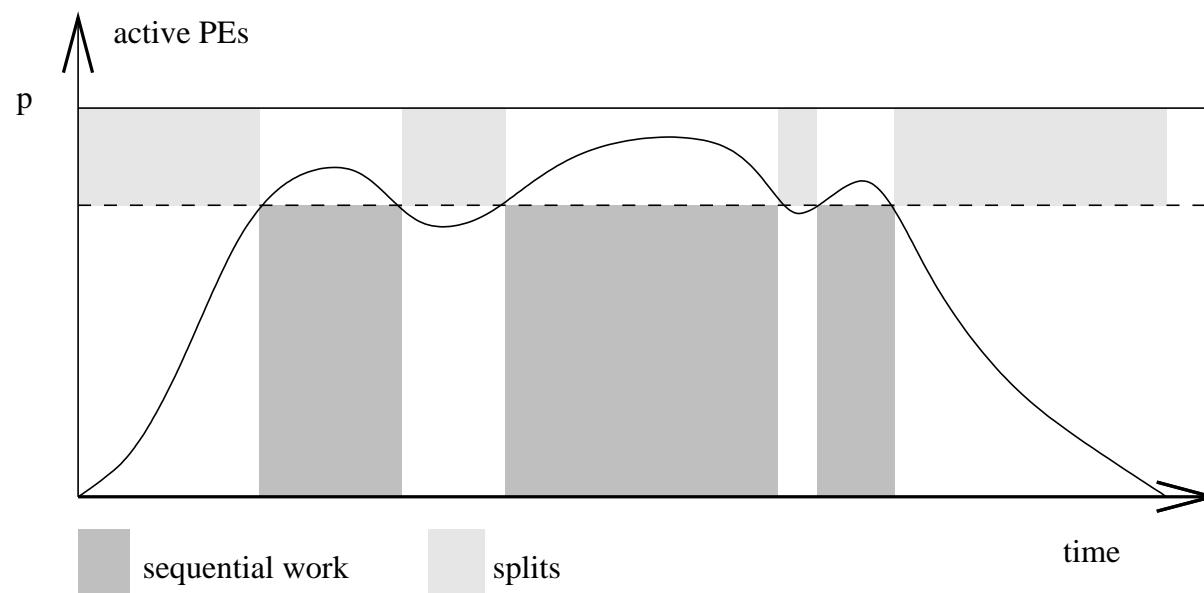
            send empty subproblems the rest

**if**  $T(P) = 0$  **then** receive P

# Analysis

**Satz 5.** For all  $\varepsilon > 0$  there is a choice of  $\Delta t$  and  $m$  such that

$$T_{\text{par}} \preceq (1 + \varepsilon) \frac{T_{\text{seq}}}{p} + \tilde{\mathcal{O}}(T_{\text{atomic}} + h(T_{\text{rout}}(l) + T_{\text{coll}} + T_{\text{split}})) .$$



# Bounding Idleness

## Lemma 6.

Let  $m < p$  with  $m \in \Omega(p)$ .

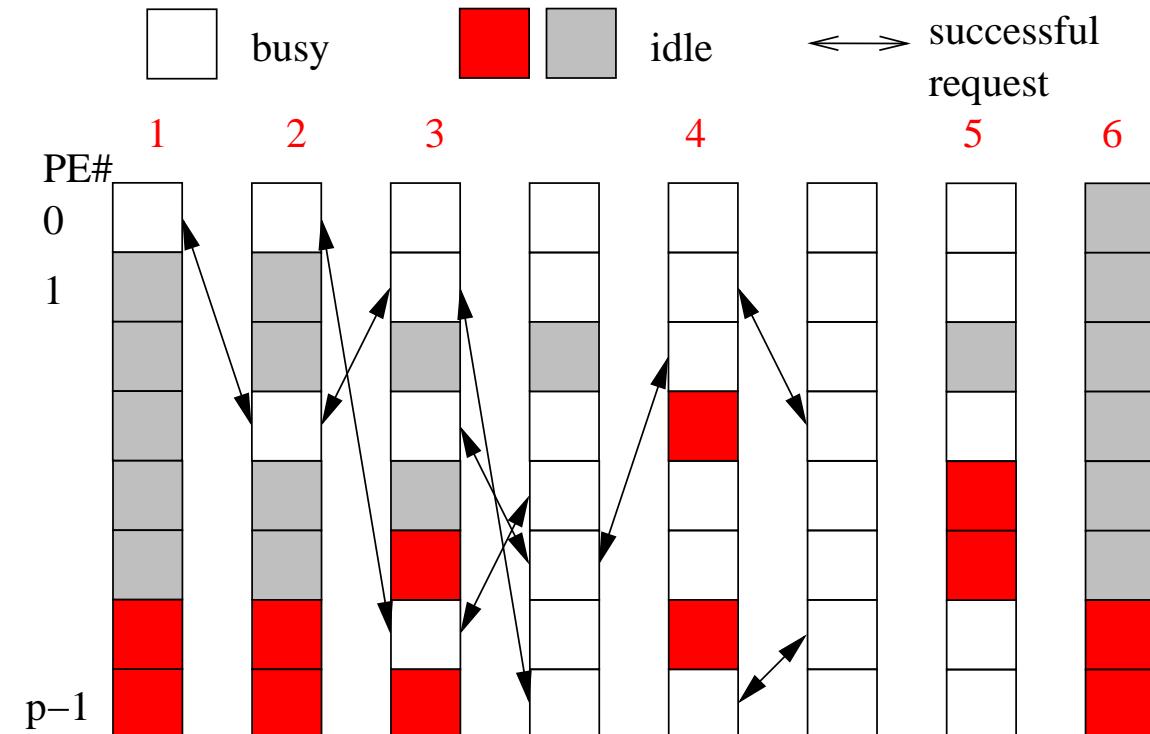
Then  $\tilde{O}(h)$  iterations

with at least

$m$  empty subproblems

suffice to ensure

$\forall P : \text{gen}(P) \geq h$  .



# Busy phases

**Lemma 7.** *There are at most  $\frac{T_{\text{seq}}}{(p-m)\Delta t}$  iterations with  $\leq m$  idle PEs at their end.*

# A Simplified Algorithm

$P, P'$  : Subproblem

$P := \text{if } i_{\text{PE}} = 0 \text{ then } P_{\text{root}} \text{ else } P_\emptyset$

**while** not finished

$P := \text{work}(P, \Delta t)$

select a global value  $0 \leq s < n$  uniformly at random

**if**  $T(P @ i_{\text{PE}} - s \bmod p) = 0$  **then**

$(P, P @ i_{\text{PE}} - s \bmod n) := \text{split}(P)$

**Satz 8.** *For all  $\varepsilon > 0$  there is a choice of  $\Delta t$  and  $m$  such that*

$$T_{\text{par}} \preceq (1 + \varepsilon) \frac{T_{\text{seq}}}{p} + \tilde{O} \left( T_{\text{atomic}} + h(T_{\text{rout}}(l) + T_{\text{split}}) \right) .$$

# Asynchronous Random Polling

$P, P'$  : Subproblem

$P := \text{if } i_{\text{PE}} = 0 \text{ then } P_{\text{root}} \text{ else } P_\emptyset$

**while** no global termination yet **do**

**if**  $T(P) = 0$  **then** send a request to a random PE

**else**  $P := \text{work}(P, \Delta t)$

**if** there is an incoming message  $M$  **then**

**if**  $M$  is a request from PE  $j$  **then**

$(P, P') := \text{split}(P)$

send  $P'$  to PE  $j$

**else**

$P := M$

# Analysis

## Satz 9.

$$\begin{aligned}\mathbb{E}T_{\text{par}} \leq & (1 + \varepsilon) \frac{T_{\text{seq}}}{p} + \\ & \mathcal{O} \left( T_{\text{atomic}} + h \left( \frac{1}{\varepsilon} + T_{\text{rout}} + T_{\text{split}} \right) \right)\end{aligned}$$

*for an appropriate choice of  $\Delta t$ .*

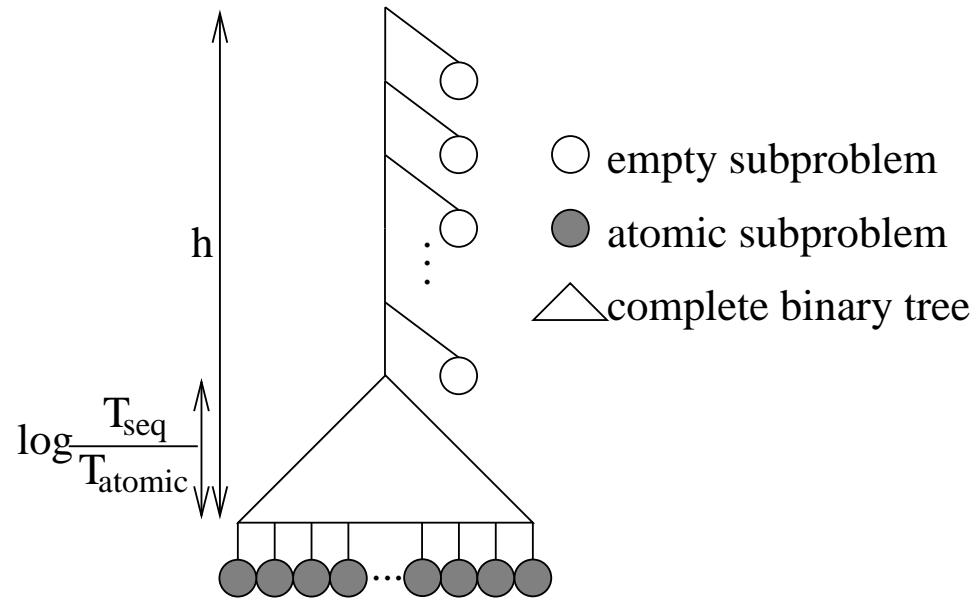
# A Trivial Lower Bound

**Satz 10.** *For all tree shaped computations*

$$T_{\text{par}} \in \Omega \left( \frac{T_{\text{seq}}}{p} + T_{\text{atomic}} + T_{\text{coll}} + T_{\text{split}} \log p \right) .$$

*if efficiency in  $\Omega(1)$  shall be achieved.*

# Many Consecutive Splits

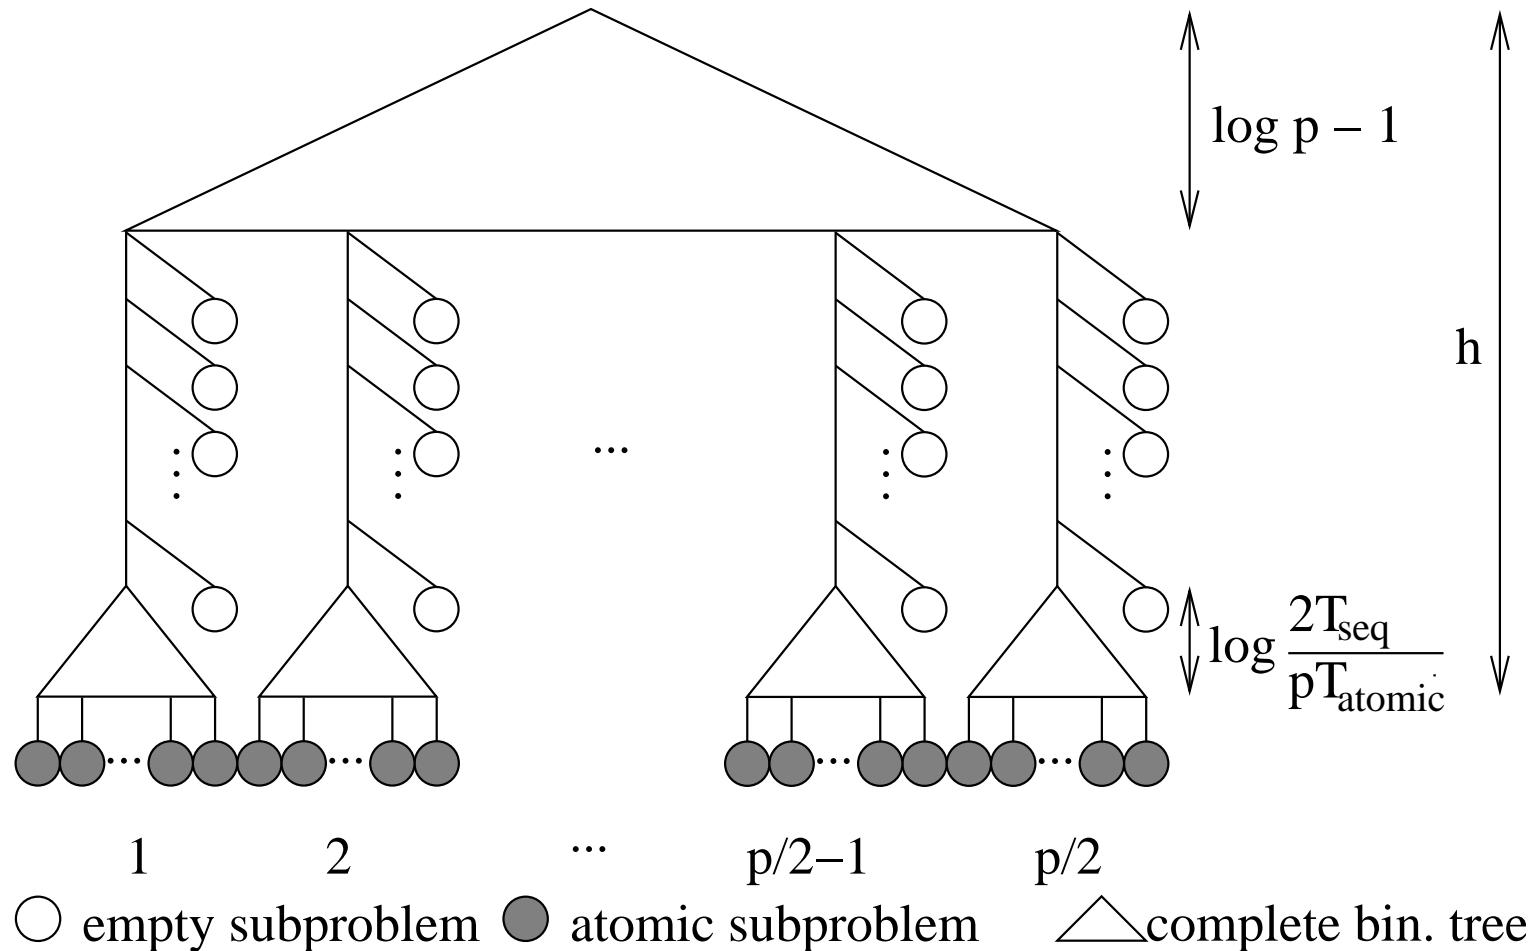


Additional

$$h - \log \frac{T_{\text{seq}}}{T_{\text{atomic}}}$$

term.

# Many Splits Overall



**Satz 11.** *Some problems need at least*

$$\frac{p}{2} \left( h - \log \frac{T_{\text{seq}}}{T_{\text{atomic}}} \right)$$

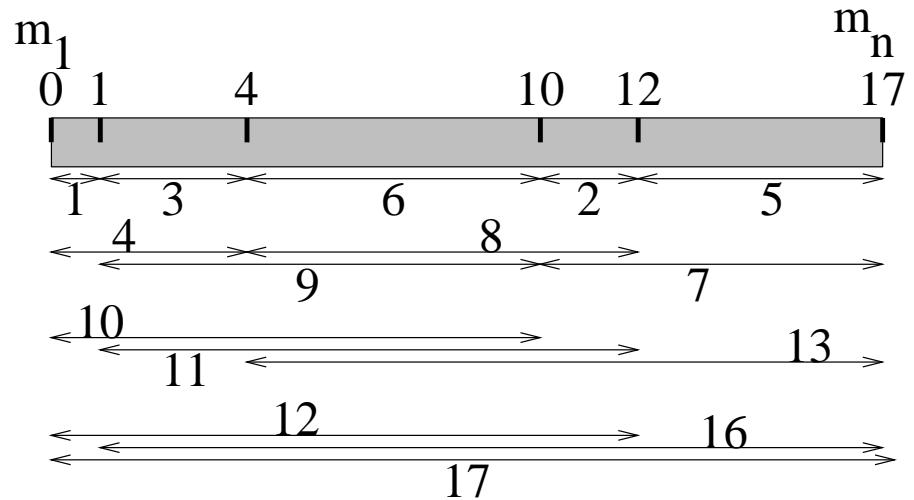
*splits for efficiency  $\geq \frac{1}{2}$ .*

**Korollar 12.** *Receiver initiated algorithms need a corresponding number of communications.*

**Satz 13** (Wu and Kung 1991). *A similar bound holds for all deterministic load balancers.*

# Golomb-Rulers

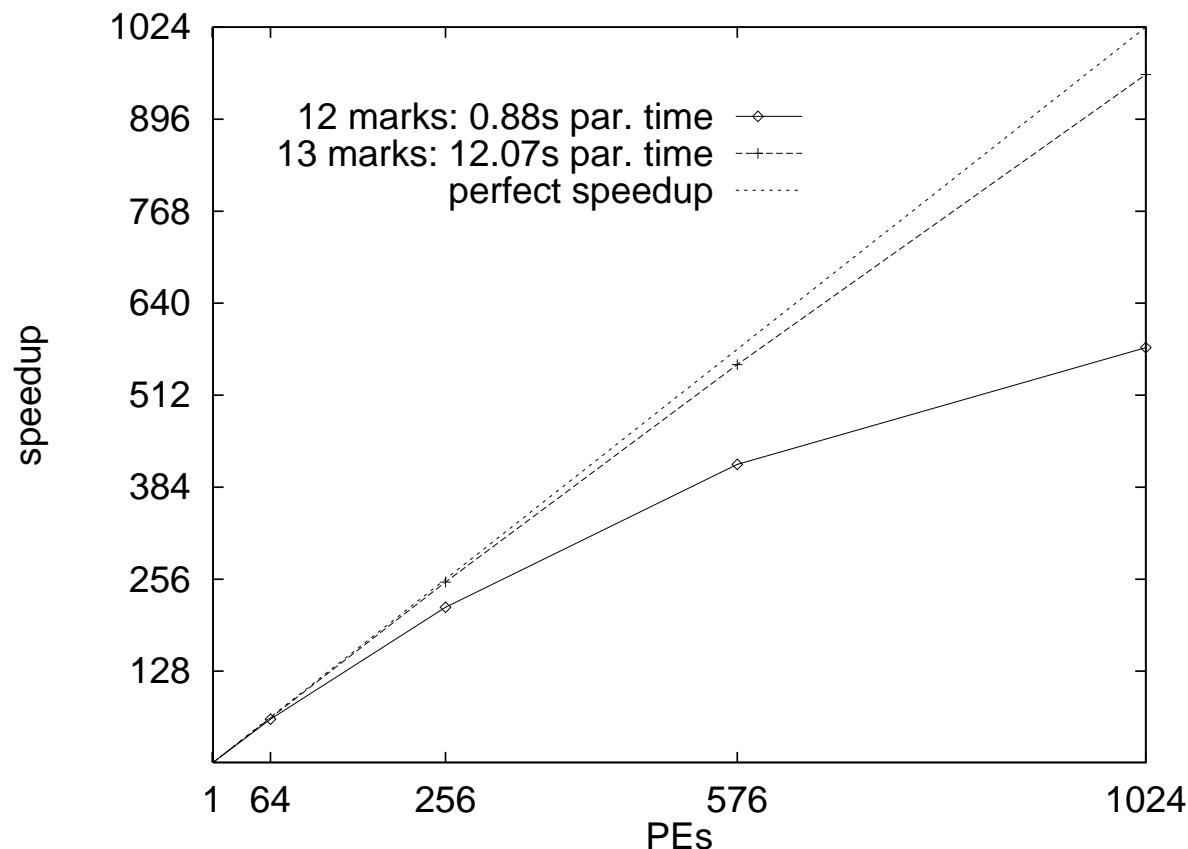
- Total length  $m$
- find  $n$  marks  $\{m_1, \dots, m_n\} \subseteq \mathbb{N}_0$
- $m_1 = 0, m_n = m$
- $|\{m_j - m_i : 1 \leq i < j \leq n\}| = n(n-1)/2$



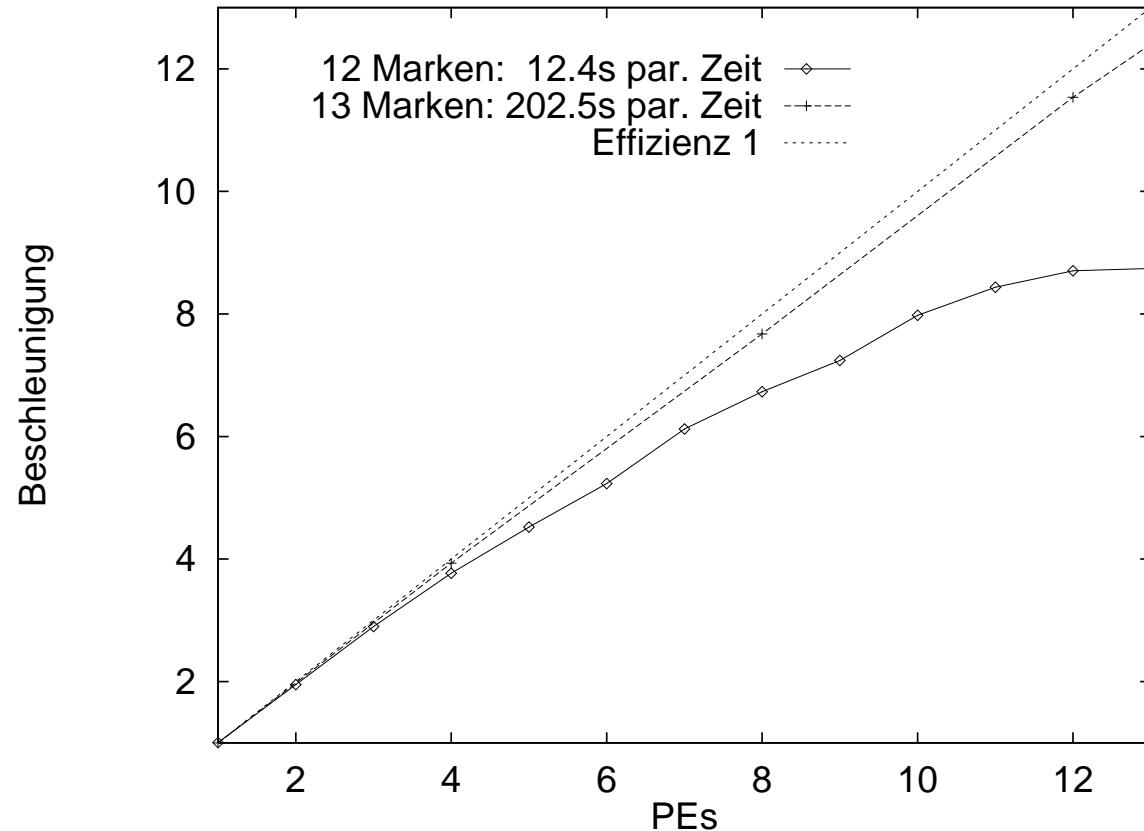
Applications: Radar astronomy, codes, ...

# Many Processors

- Parsytec GCel-3/1024 with COSY (PB)
- Verification search



# LAN



- Differing PE-Speeds (even dynamically) are unproblematic.
- Even complete suspension OK as long as requests are answered.

# The 0/1-Knapsack Problem

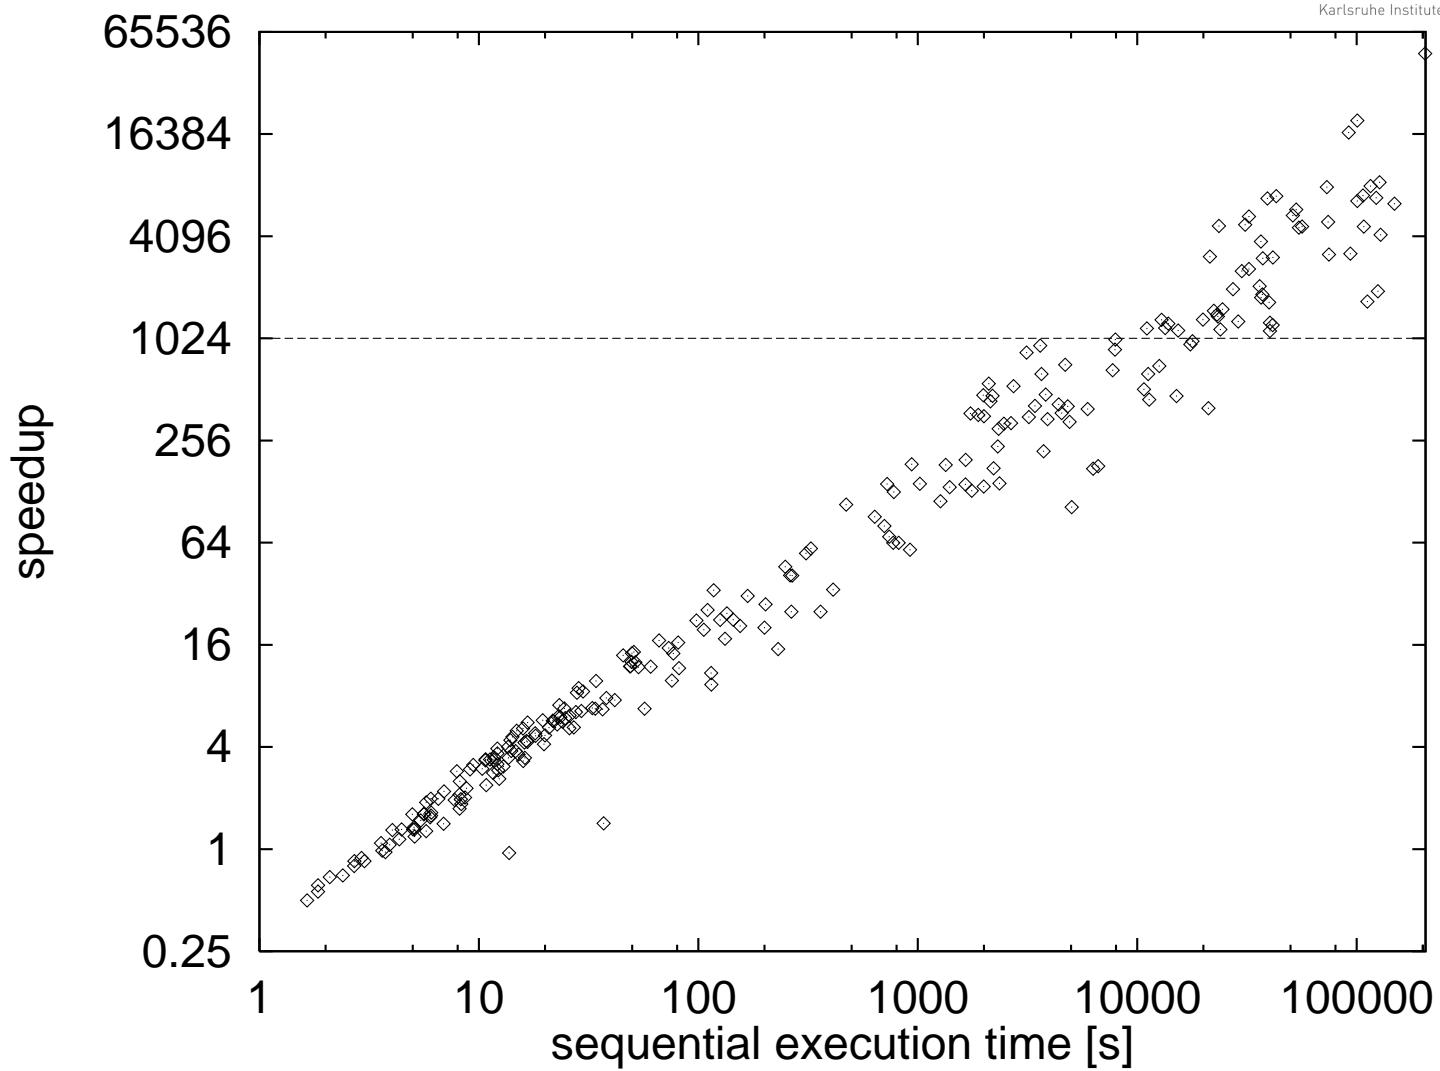
- $m$  items
- maximum knapsack weight  $M$
- item weights  $w_i$
- item profits  $p_i$
- Find  $x_i \in \{0, 1\}$  such that
  - $\sum w_i x_i \leq M$
  - $\sum p_i x_i$  is maximized

## Best known approach for large $m$ :

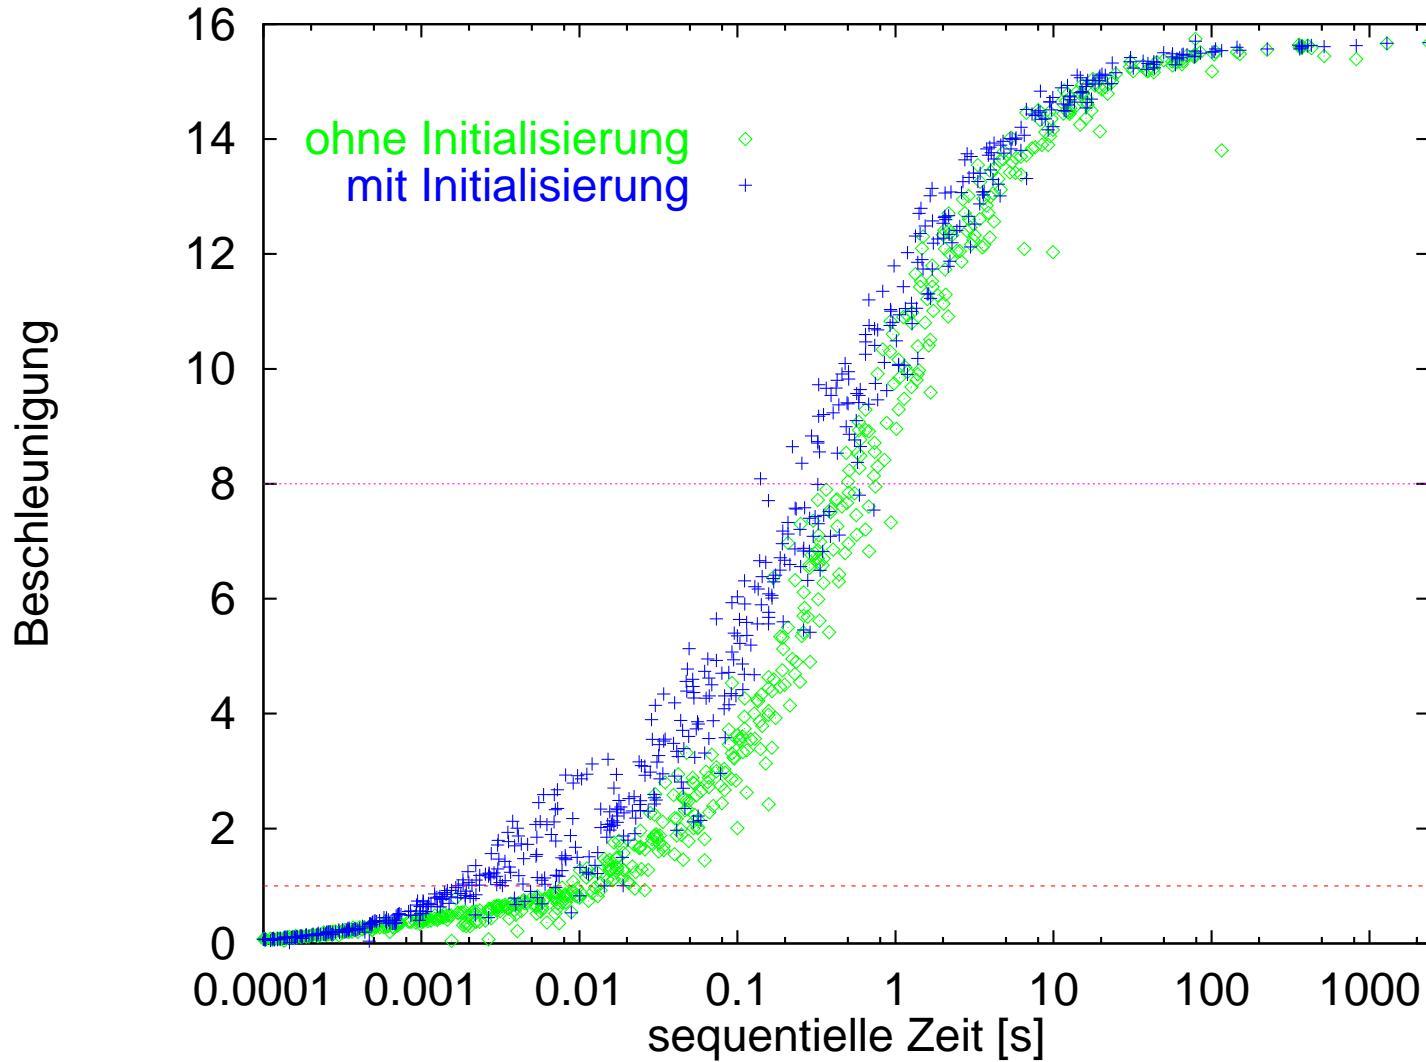
- Depth-first branch-and-bound
- Bounding function based on a the relaxation  $x_i \in [0, 1]$ . (Can be computed in  $\mathcal{O}(\log m)$  steps.)

# Superlinear Speedup

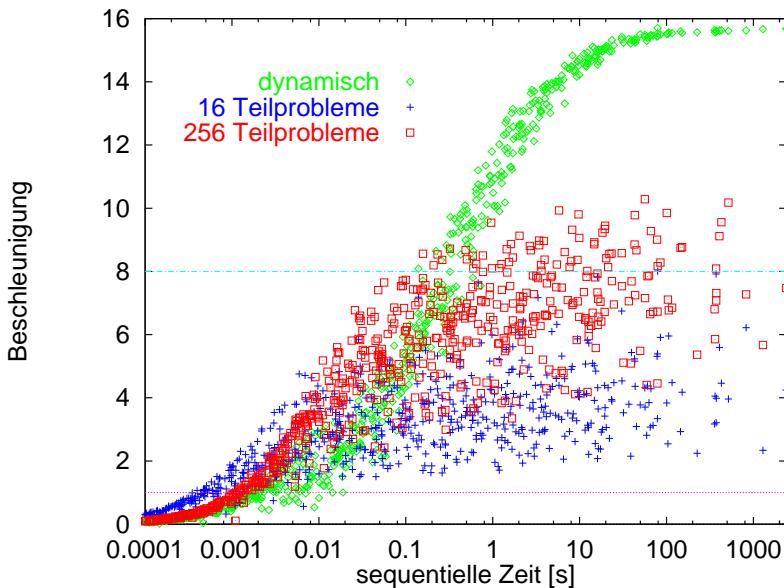
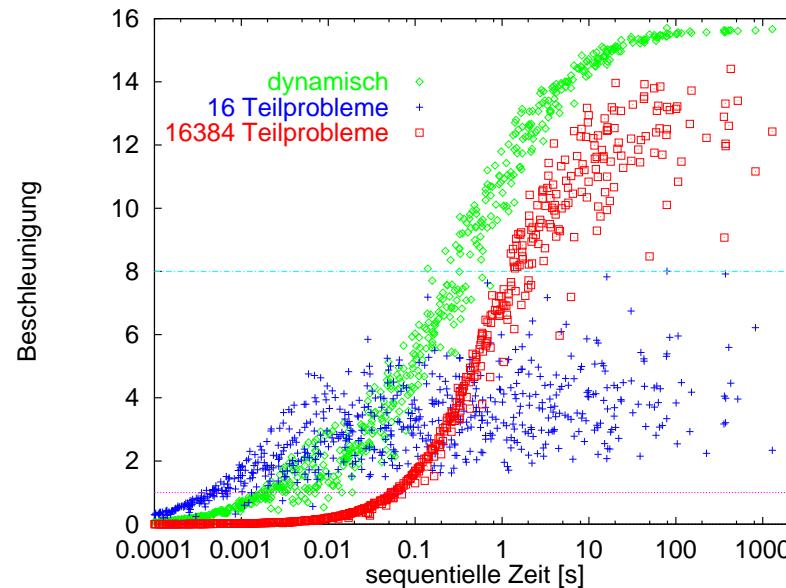
- Parsytec GCel-3/1024 under CosY (PB)
- 1024 processors
- 2000 items
- Splitting on all levels
- 256 random instances at the border between simple and difficult
- overall  $1410 \times$  faster than seq. computation!



# Fast Initialization

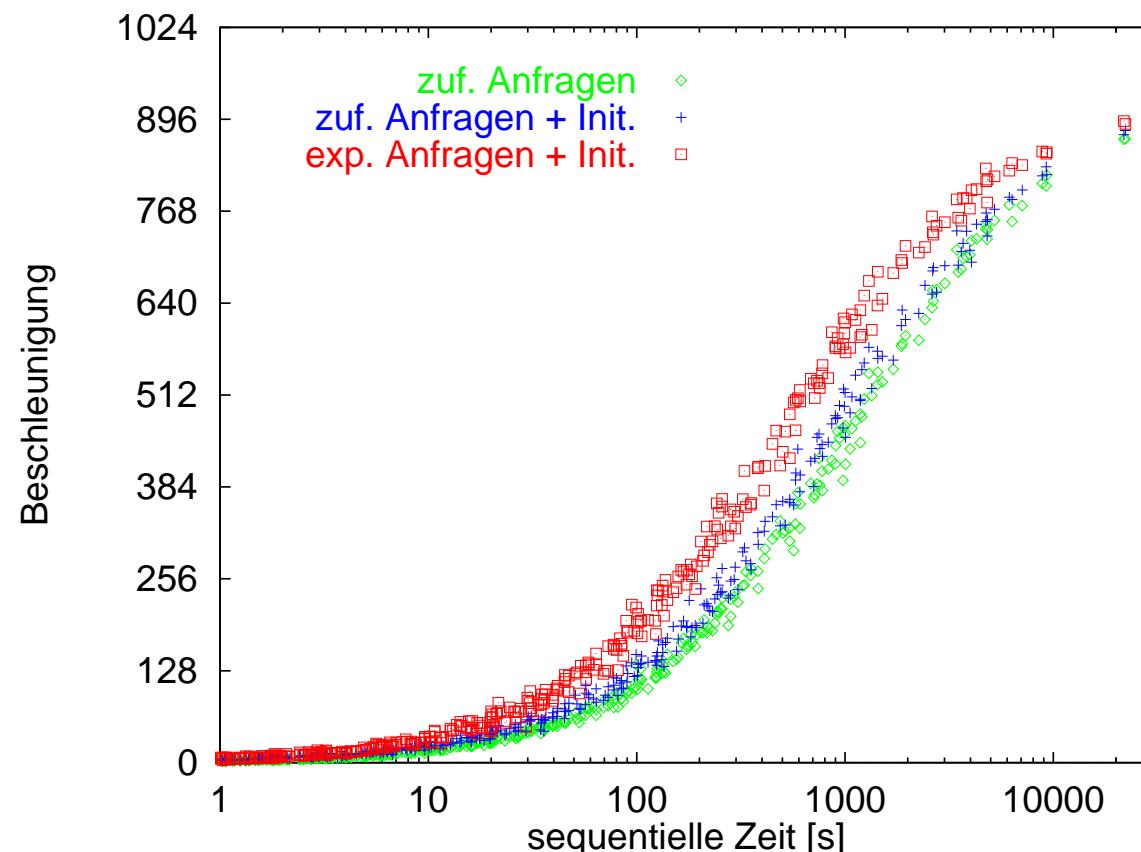


# Static vs Dynamic LB



# Beyond Global Polling

- Randomized Initialization
- Asynchronously increase polling range (exponentially)



# Game Tree Search

- Naive Parallelization yields only Speedup  $\mathcal{O}(\sqrt{n})$ .
- Young Brother Wait Concept (Feldmann et al.)
- Tradeoff between Speculativity and Sequentialization
- Propagate window updates
- Combine with global transposition table

# MapReduce in 10 Minutes

[Google, DeanGhemawat OSDI 2004] siehe auch Wikipedia

**Framework** zur Verarbeitung von Multimengen von (key, value) Paaren.

// $M \subseteq K \times V$

// $\text{MapF} : K \times V \rightarrow K' \times V'$

// $\text{ReduceF} : K' \times 2^{V'} \rightarrow V''$

**Function**  $\text{mapReduce}(M, \text{MapF}, \text{ReduceF}) : V''$

$M' := \{\text{MapF}((k, v)) : (k, v) \in M\}$  // easy (load balancing?)

$\text{sort}(M')$  // basic toolbox

**forall**  $k'$  with  $\exists(k', v') \in M'$  **dopar** // easy

$s := \{v' : (k', v') \in M'\}$

$S := S \cup (k', s)$

**return**  $\{\text{reduceF}(k', s) : (k', s) \in S\}$  // easy (load balancing?)

# Refinements

- Fault Tolerance
- Load Balancing using hashing (default) und Master-Worker
- Associative commutative reduce functions

# Examples

- Grep
- URL access frequencies
- build inverted index
- Build reverse graph adjacency array

# Graph Partitioning

## Contraction

**while**  $|V| > c \cdot k$  **do**

    find a matching  $M \subseteq E$

    contract  $M$            // similar to MST algorithm (more simple)

save each generated level

# Finding a Matching

Find approximate max. weight matching wrt **edge rating**

$$\text{expansion}(\{u, v\}) := \frac{\omega(\{u, v\})}{c(u) + c(v)}$$

$$\text{expansion}^*(\{u, v\}) := \frac{\omega(\{u, v\})}{c(u)c(v)}$$

$$\text{expansion}^{*2}(\{u, v\}) := \frac{\omega(\{u, v\})^2}{c(u)c(v)}$$

$$\text{innerOuter}(\{u, v\}) := \frac{\omega(\{u, v\})}{\text{Out}(v) + \text{Out}(u) - 2\omega(u, v)}$$

# Approx. max. weighted Matching

todo

# Graph Partitioning Future Work

- Understand edge ratings
- Scalable parallel weighted Matching code
- Hypergraph partitioning
- Handling exact balance
- Max. Flow. based techniques
- Parallel external, e.g., partitioning THE web graph