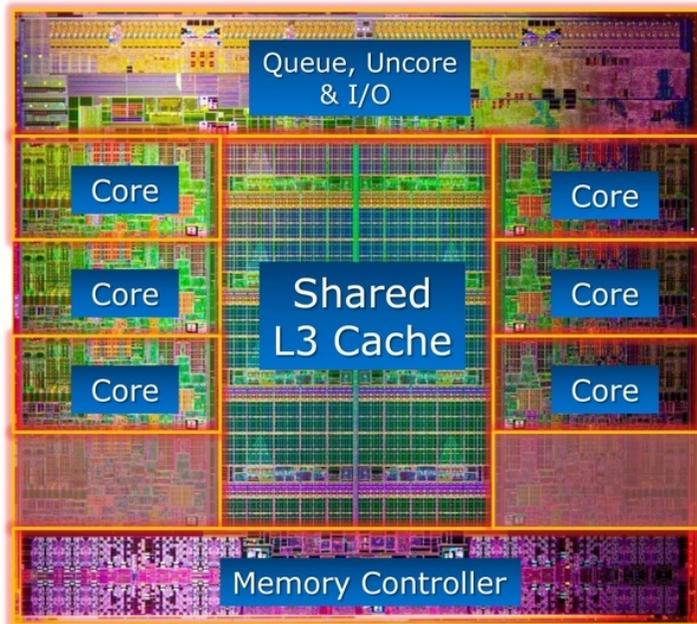


Parallele Algorithmen

Peter Sanders

Institut für Theoretische Informatik



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 \cdot 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

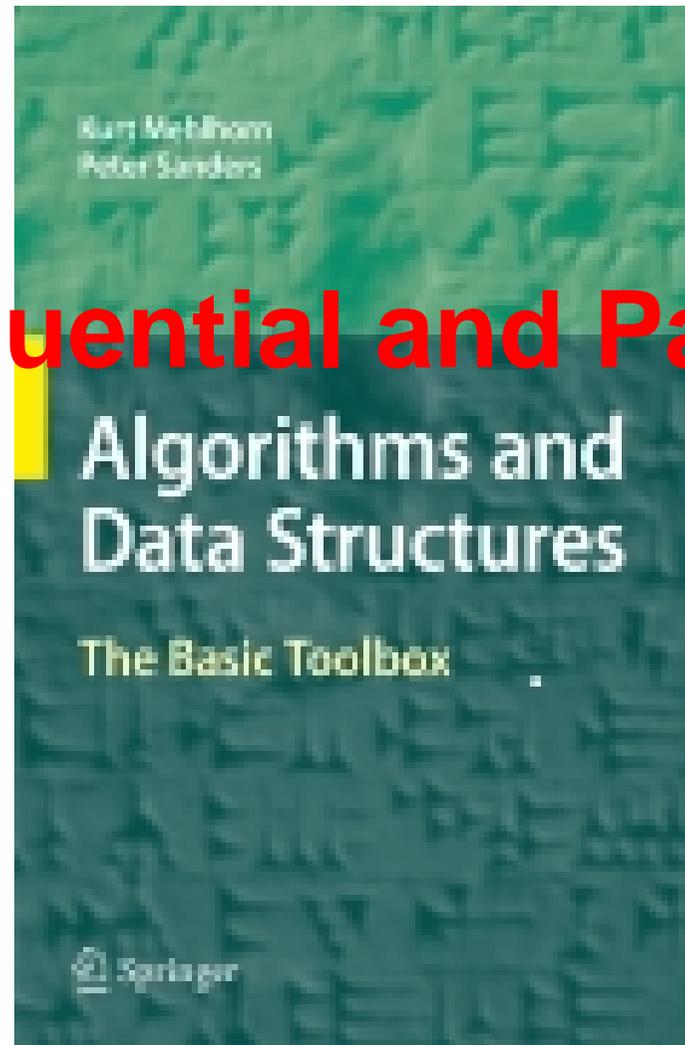
- Modelle, Einfache Beispiele
- Matrixmultiplikation
- Broadcasting
- Sortieren
- Allgemeiner Datenaustausch
- Lastverteilung I,II,III
- Umwandlung verkettete Liste \rightarrow Array
- Hashing, Prioritätslisten
- einfache Graphenalgorithmen
- Graphpartitionierung

Literatur

Skript

+

Sequential and Parallel



Viele Abbildungen etc. übernommen markiert durch [\[Book\]](#).

Mehr Literatur

[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.

Parallelverarbeitung am ITI Sanders

- Massiv paralleles Sortieren, Michael Axtmann
- Massiv parallele Graph-Algorithmen, Sebastian Lamm
- Fehlertoleranz, Demian Hesse
- Big-Data Framework Thrill, Timo Bingmann
- Shared Memory Datenstrukturen, Tobias Maier
- (Hyper)Graphpartitionierung, Sebastian Schlag & Yaroslav Akhremtsev
- Kommunikationseff. Alg., Lorenz Hübschle-Schneider
- SAT-Solving und Planungsprobl., Tomas Balyo & Dominik Schreiber
- Geometrische Algorithmen, Daniel Funke

Einbettung in das Informatik-Studium

- Wahlfach oder Mastervorzug im **Bachelorstudium!**
- Vertiefungsfach
 - Algorithmentechnik
 - Parallelverarbeitung
- Studienprofil daten-intensives Rechnen

Schwesterveranstaltungen

Parallelprogrammierung: Tichy, Karl, Streit

Modelle der Parallelverarbeitung: viel theoretischer,
Komplexitätstheorie,...

Worsch

Algorithmen in Zellularautomaten: spezieller, radikaler, theoretischer
Worsch

Rechnerarchitektur: Karl

GPUs: Dachsbacher

+ andere **Algorithmmikvorlesungen**

RAM/von Neumann Modell

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

- Einfach
- Sehr erfolgreich

$O(1)$ registers



1 word = $O(\log n)$ bits

freely programmable
large memory



Algorithmenanalyse:

□ Zyklen zählen: $T(I)$, für gegebene Problem Instanz 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 $\mathbb{E}[T(n)] = \mathcal{O}(n \log n)$

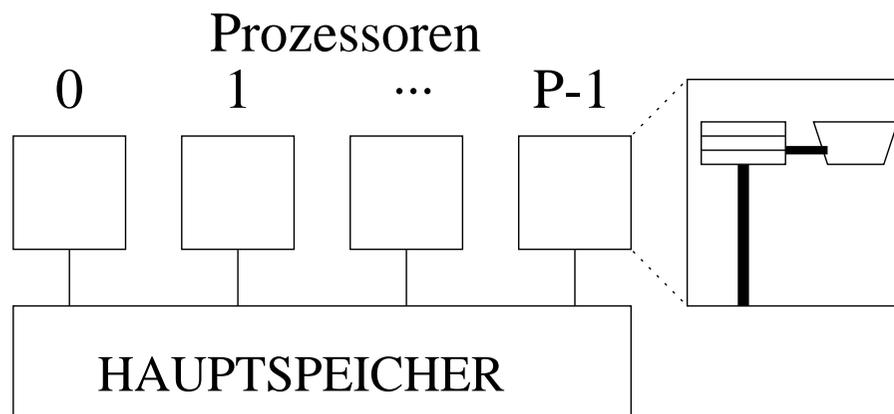
Algorithmenanalyse: Noch mehr Konventionen

- $\mathcal{O}(\cdot)$ 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 (**P**rozessor**E**lemente); 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

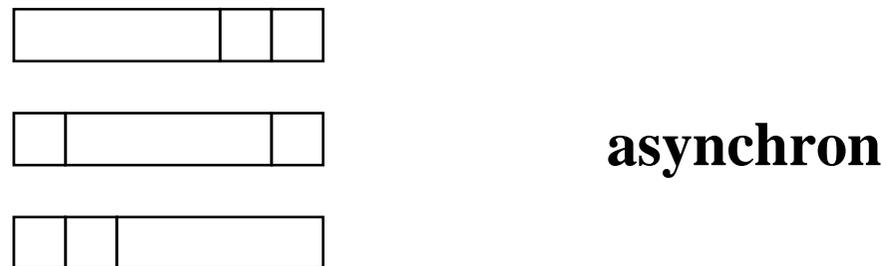
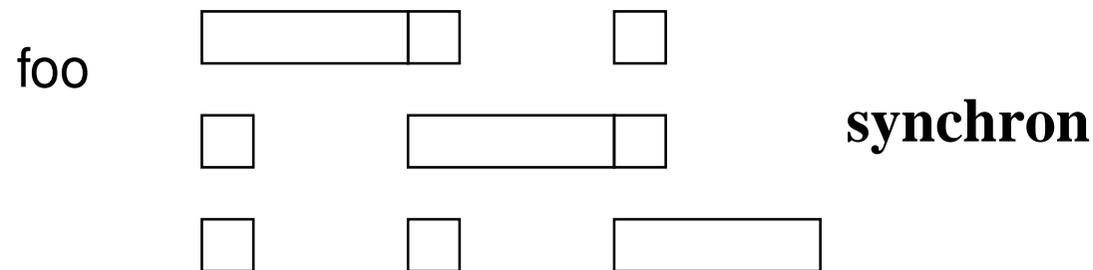
PE index is j

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: $W = \Theta(n^2)$)

Span: $T_\infty = \sup_p T(p)$ mißt Parallelisierbarkeit.

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

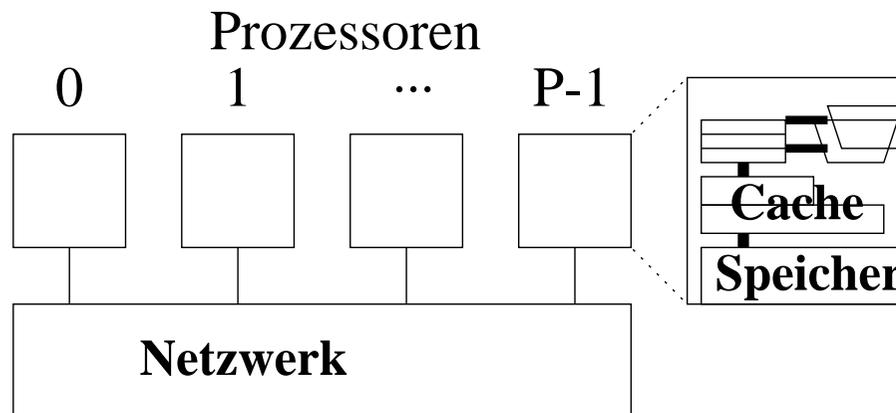
Effizienz: $E = S/p$. Ziel: $E \approx 1$ oder wenigstens $E = \Theta(1)$.

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

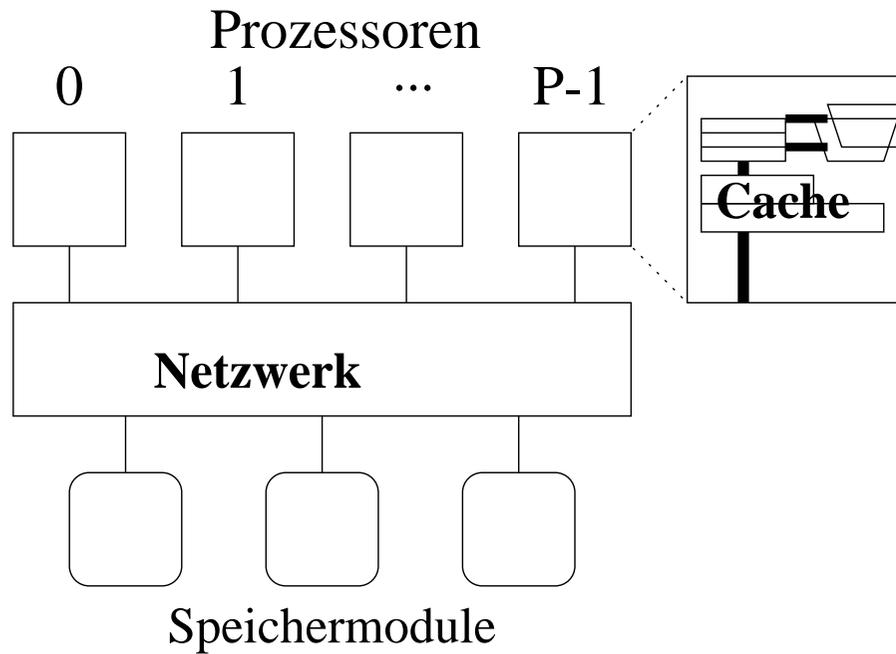
(möglich?). Beispiel Maximum: $E = \Theta(1/n)$.

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/cache lines.
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

Realistic Shared Memory Models

- asynchronous
- aCRQW**: **asynchronous** concurrent read **queued write**. When x PEs contend for the same memory cell, this costs time $\mathcal{O}(x)$.
- consistent write operations using **atomic operations**
- memory hierarchies

Why is concurrent read OK?

Atomare Instruktionen: Compare-And-Swap

Allgemein und weit verbreitet:

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

BeginTransaction

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

else

EndTransaction

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

expected := $*a$; **return** 0// failure

Weitere Operationen für konsistenten Speicherzugriff:

- Fetch-and-add
- Hardwaretransaktionen

Function fetchAndAdd(a, Δ)

expected := * a

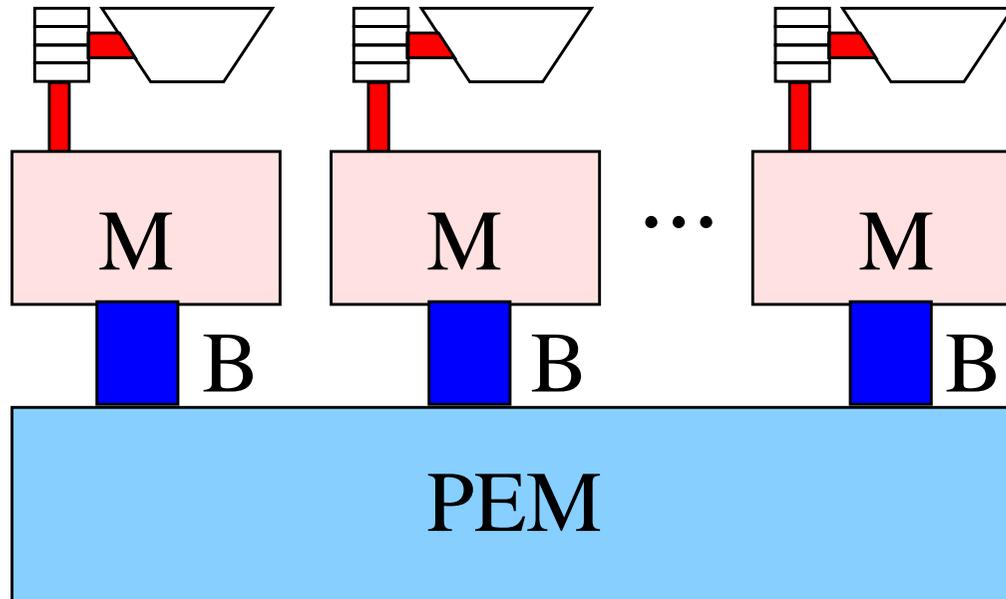
repeat

 desired := expected + Δ

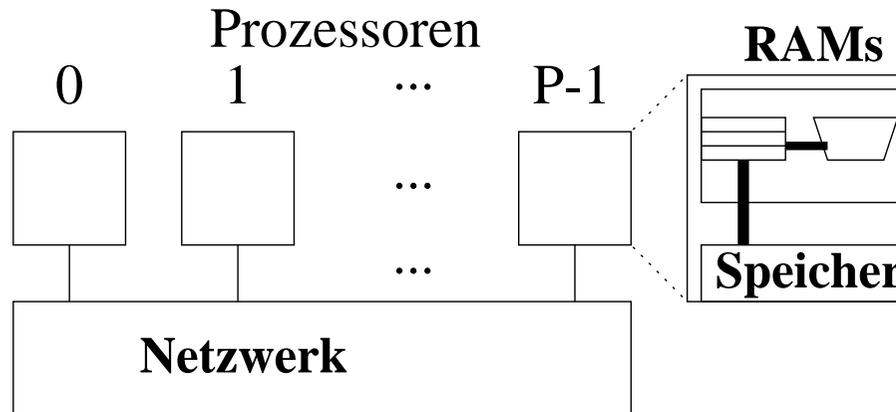
until CAS(a , expected, desired)

return desired

Parallel External Memory



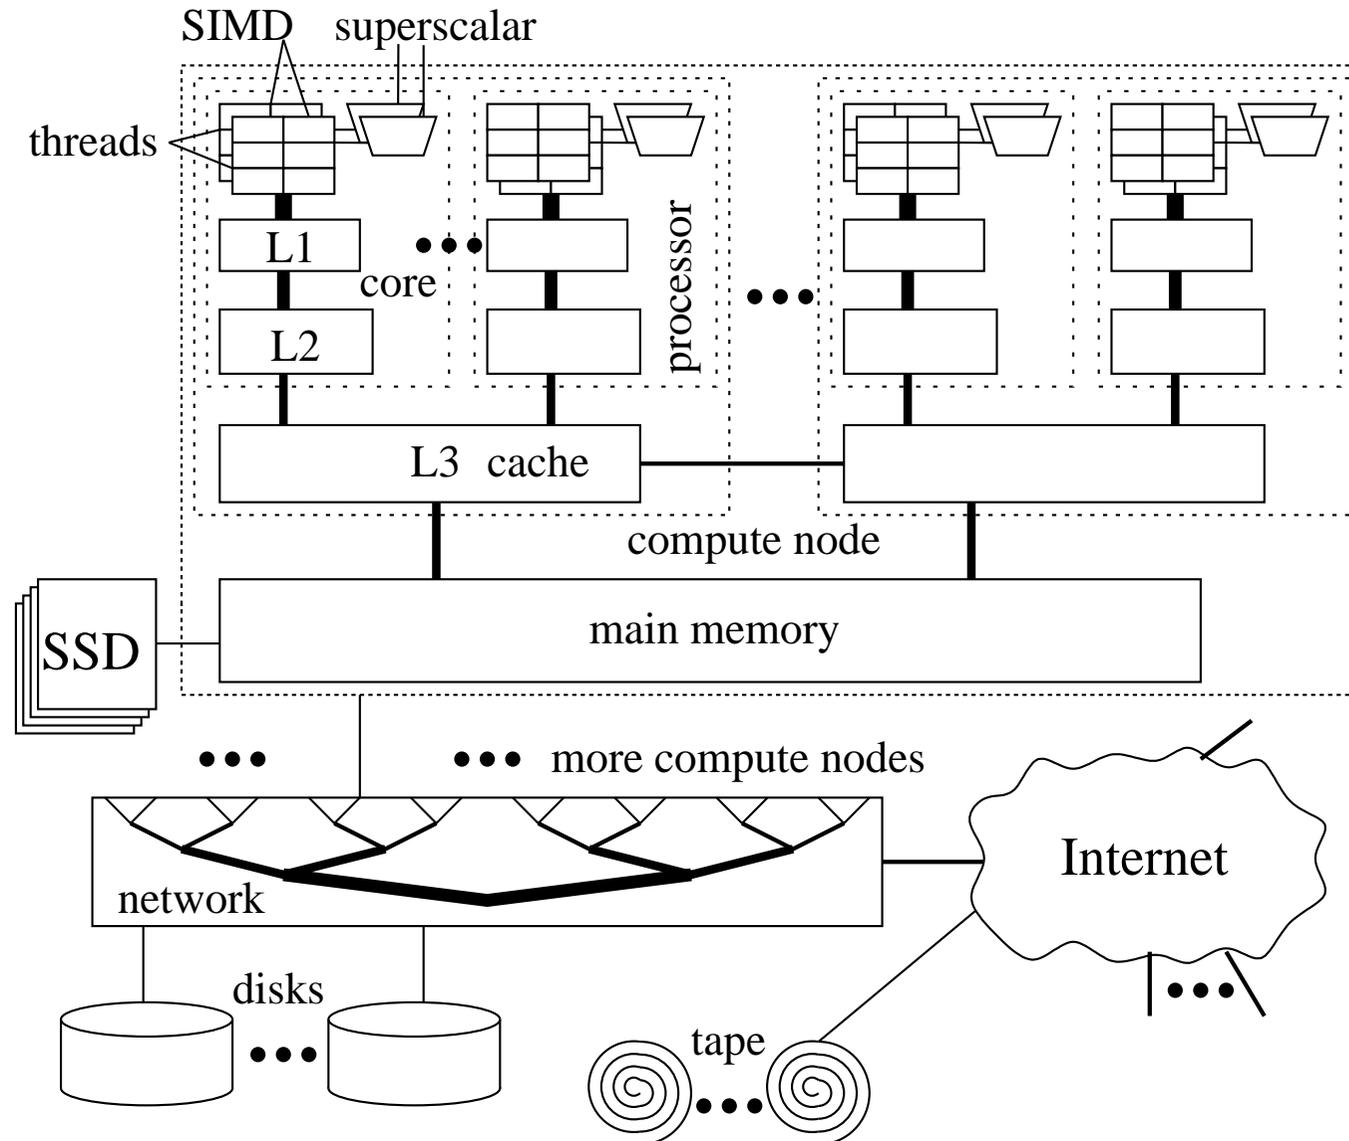
Modelle mit Verbindungsnetzwerken



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

Entscheidend ist das Kostenmodell für den Nachrichtenaustausch

Reale Maschinen Heute



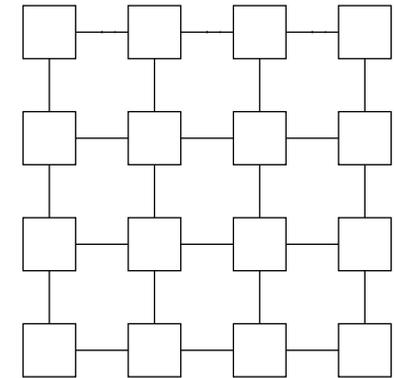
Umgang mit komplexen Hierarchien

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“

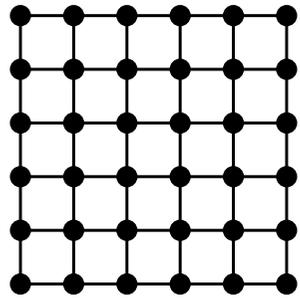
- Wir kennen die Struktur des Verbindungsgraphen ($V = \{1, \dots, p\}$, $E \subseteq V \times V$). Varianten:
 - $V = \{1, \dots, p\} \cup R$ mit zusätzlichen „dummen“ Routerknoten (ggf. mit Pufferspeicher).
 - Busse \rightarrow Hyperedges
- Zu jeder Zeiteinheit kann jede Kante maximal k' Datenpakete 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**.



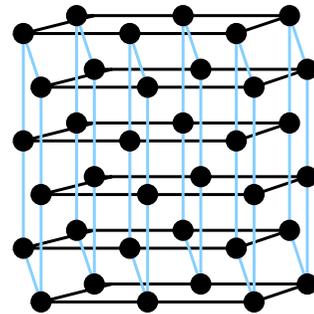
Diskussion

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

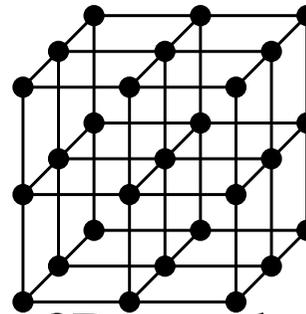
Typische Verbindungsnetzwerke



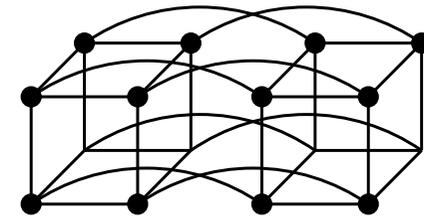
mesh



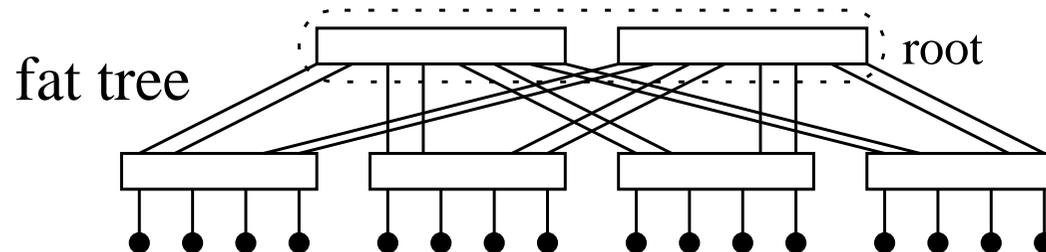
torus



3D-mesh



hypercube



fat tree

root

[Book]

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: $1 \times$ senden **oder** $1 \times$ empfangen (auch simplex)

Telefon: $1 \times$ senden an PE j **und** $1 \times$ empfangen **von** PE j

(voll)duplex: $1 \times$ senden **und** $1 \times$ 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 .

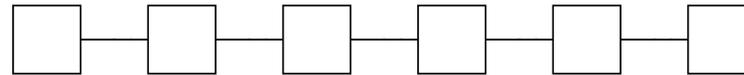
l : Startup overhead für einen **kollektiven** Nachrichtenaustausch – an dem alle PEs beteiligt sind

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

Formaler: Eine **h -Relation** ist ein 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)

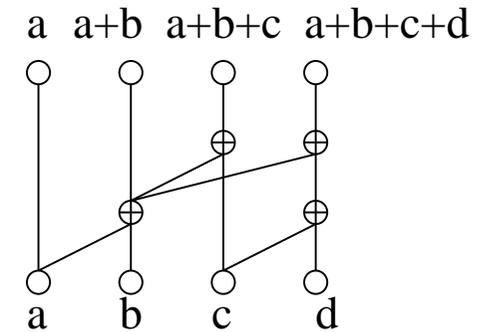
- Broadcast (einer an alle), Minimum, Maximum, Summe, ...
- Nachbarschaftskommunikation auf **logischen** Gittern (oder anderen Graphen)
- ...

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 Maschinenworten, 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 \sim Rechenzeit
- Wenn man für jede Eingabegröße (algorithmisch) einen Schaltkreis angibt, spricht man von **Schaltkreisfamilien**

Zusammenhang mit PRAMs

DAG \rightarrow 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 \rightarrow Theorie **uniformer Schaltkreisfamilien** (nicht hier [z.B. Vollmar, Worsch; Modelle der Parallelverarbeitung; Teubner 1995])

PRAM \rightarrow DAG

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

DAG \rightarrow Verbindungsnetzwerke

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

- Berechnungsknoten \rightarrow Prozessoren
- DAG-Kanten \rightarrow **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

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

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. ? nichtkommutativ?)

Beweisskizze für $n = 2^k$ (oBdA?)

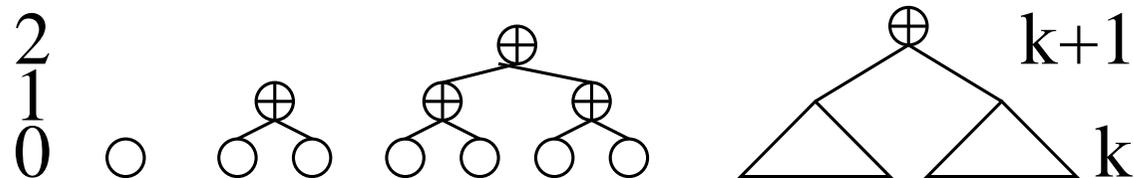
Induktionsannahme: \exists Schaltkreis d. Tiefe k für $\bigoplus_{i < 2^k} x_i$

$k = 0$: trivial

$k \rightsquigarrow k + 1$:

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

Tiefe $k+1$



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

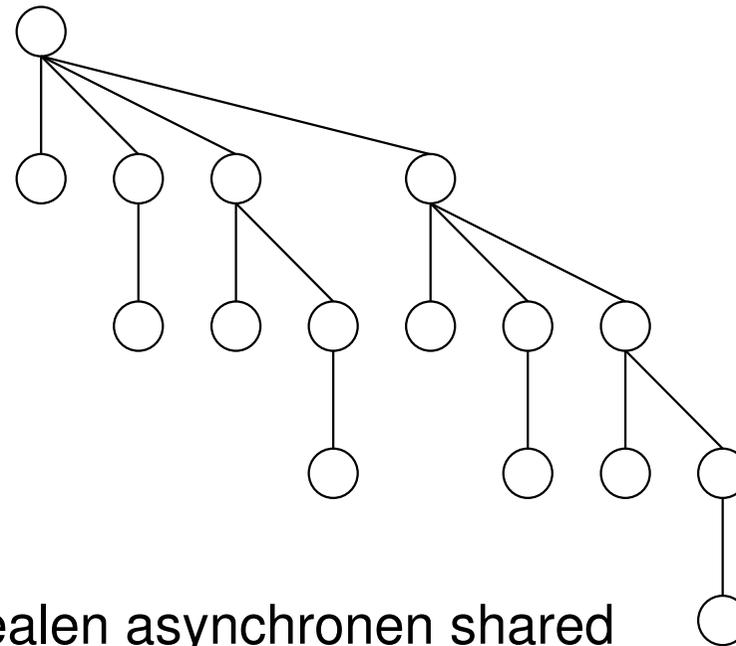
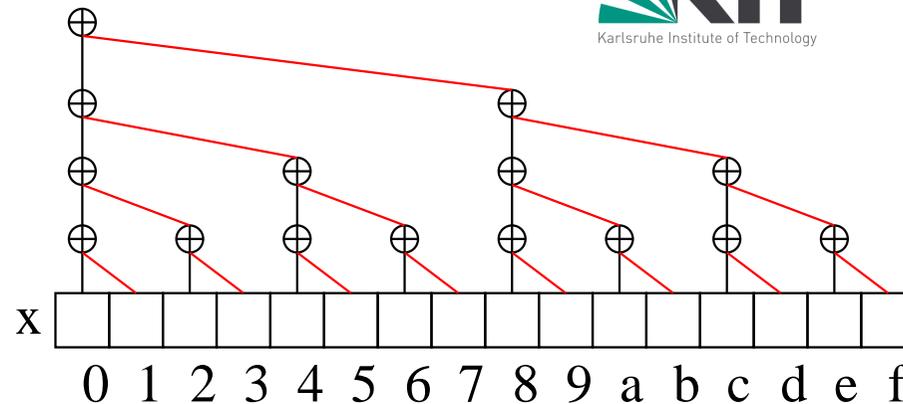
else if $i + 2^k < n$ **then**

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

//result is in x_0

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

Speedup? Effizienz?



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

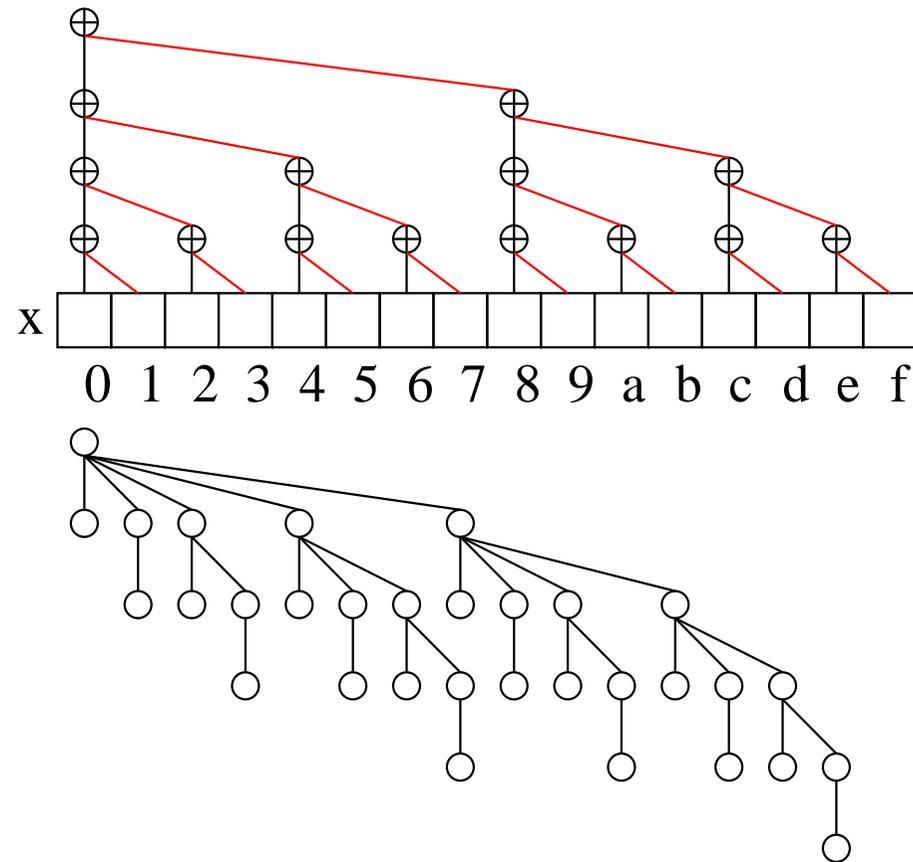
Analyse

n PEs

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

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

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



Weniger ist Mehr (Brent's Prinzip)

p PEs

Jedes PE addiert

n/p Elemente sequentiell

Dann parallele Summe

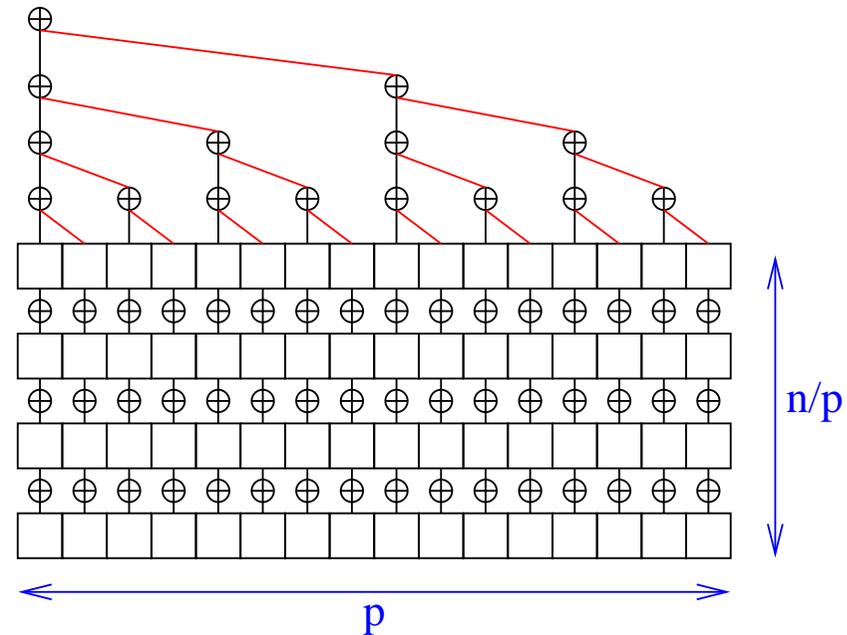
für p Teilsummen

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 $i - 2^k$

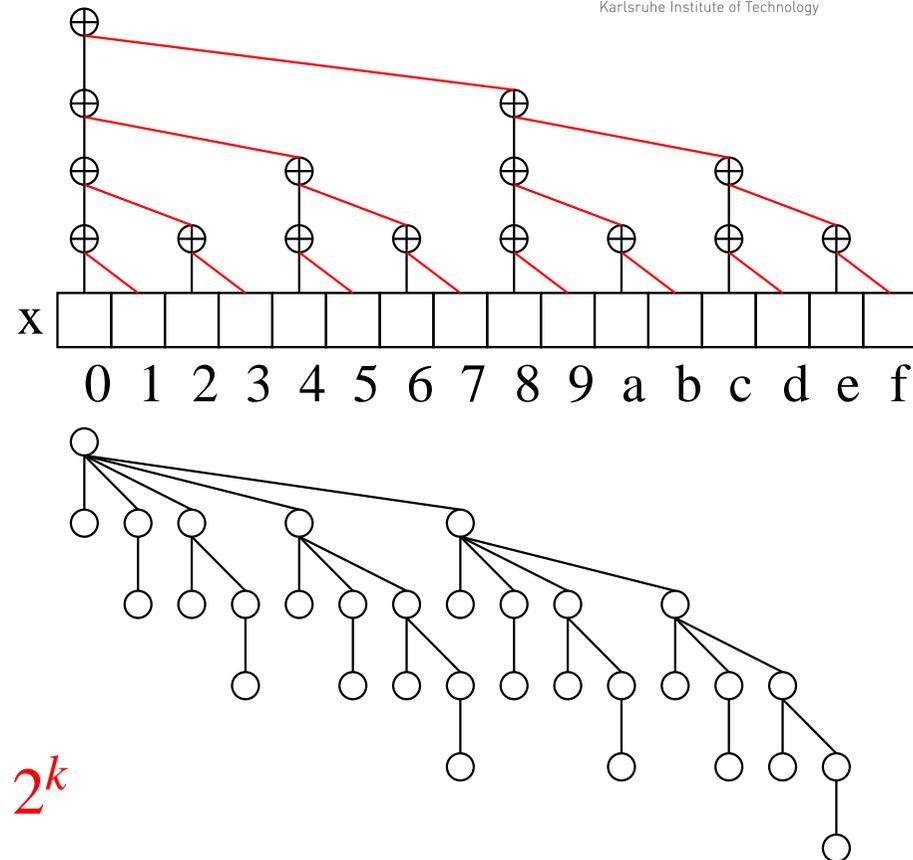
active := 0

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 $A = ((a_{ij}))$ und $B = ((b_{ij}))$

\mathbf{R} : Halbring

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

$$c_{ij} = \sum_{k=1}^n a_{ik} \cdot b_{kj}$$

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

(bessere Algorithmen falls in \mathbf{R} Subtraktion möglich)

Ein erster PRAM Algorithmus

n^3 PEs

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

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

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

// n 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**

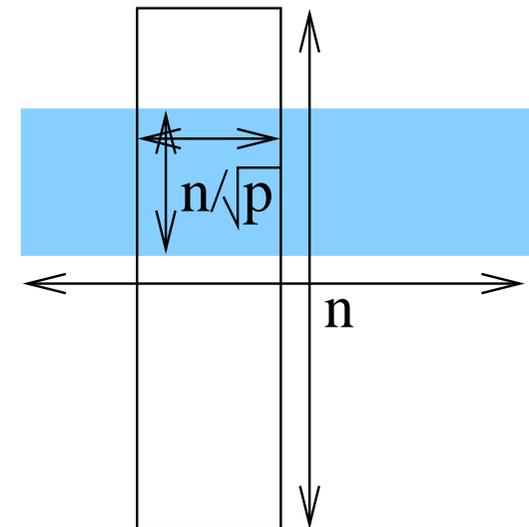
for $j:= 1$ **to** n **dopar**

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

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,

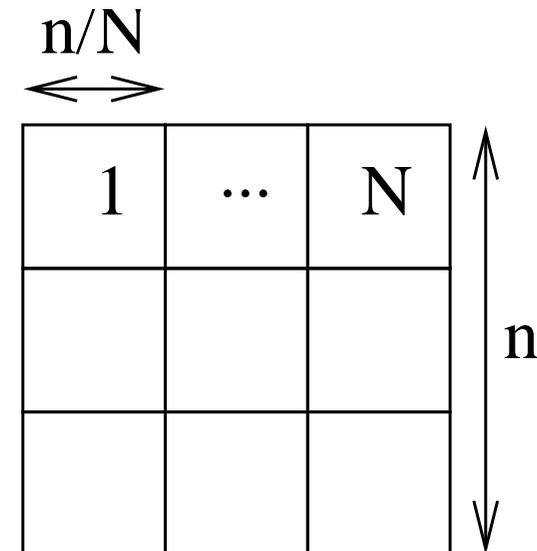
jedes Element ist $n/N \times n/N$ Matrix

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 $(i, k, 1)$

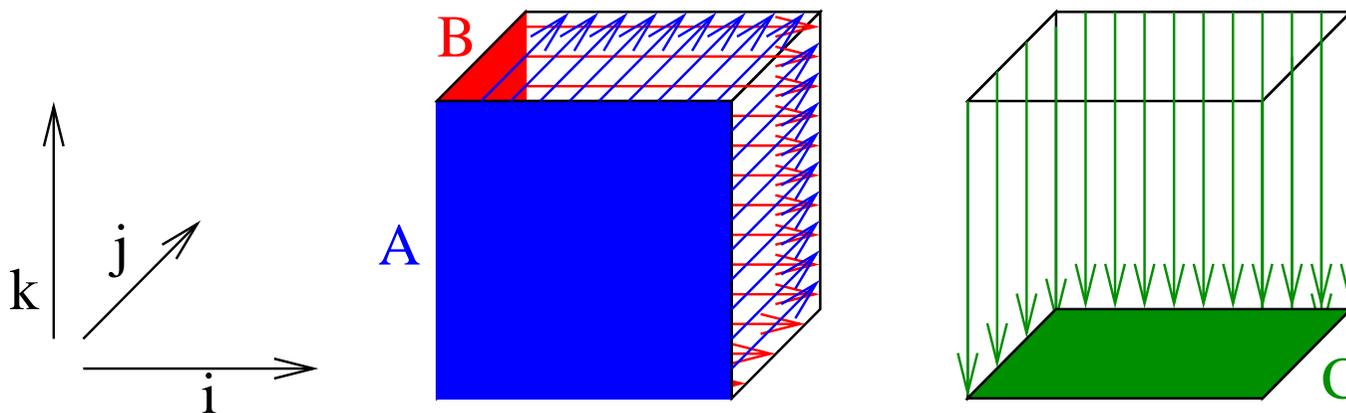
store b_{kj} in PE $(1, k, j)$

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) // $T_{\text{seq}}(n/N) = \mathcal{O}((n/N)^3)$

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

Kommunikation:

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

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

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:

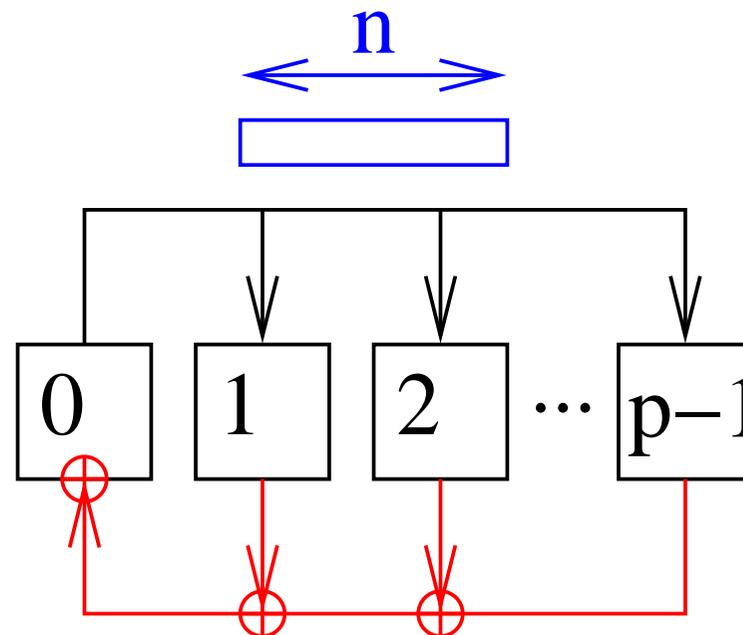
Lokale Ops auf Teilmatrizen + Broadcast + Reduce

z.B. Matrix-Vektor-Produkt, LGS lösen, . . .

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

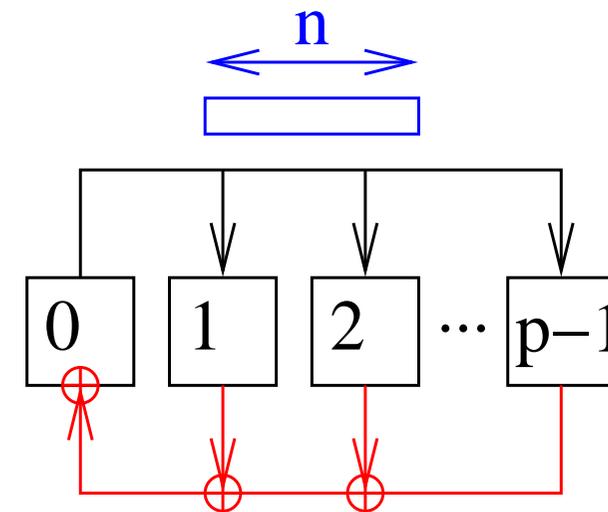
Broadcastalgorithmen ergeben

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]

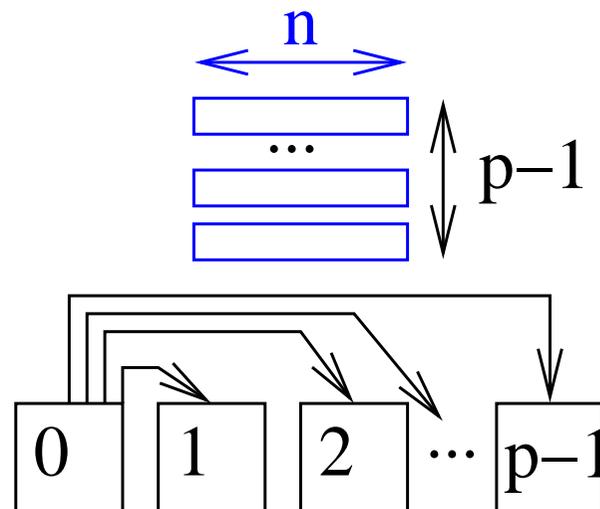
Procedure naiveBroadcast($m[1..n]$)

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

PE $i > 0$: receive m

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

Alptraum bei der Implementierung skalierbarer Algorithmen



Binomialbaum-Broadcast

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

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

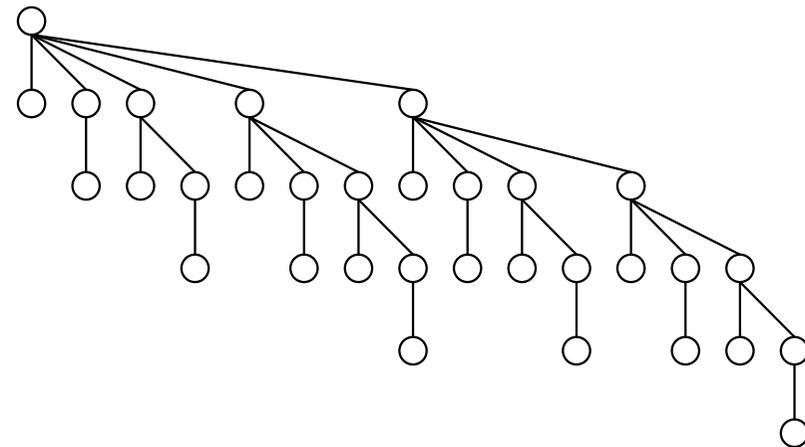
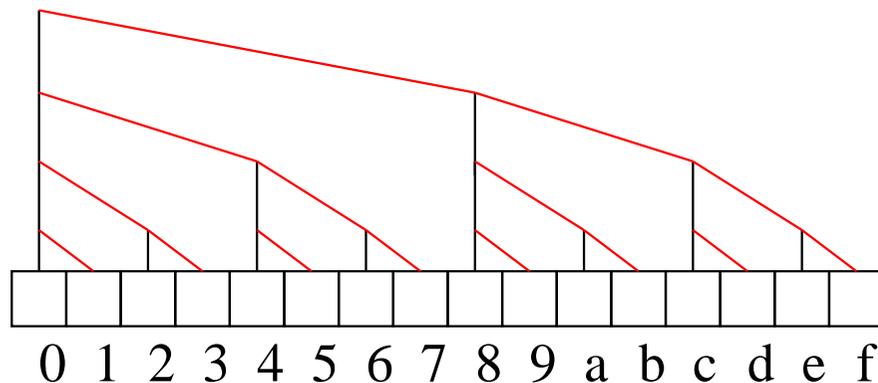
// Message m located on PE 0

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

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

 send m to PE $i + 2^k$

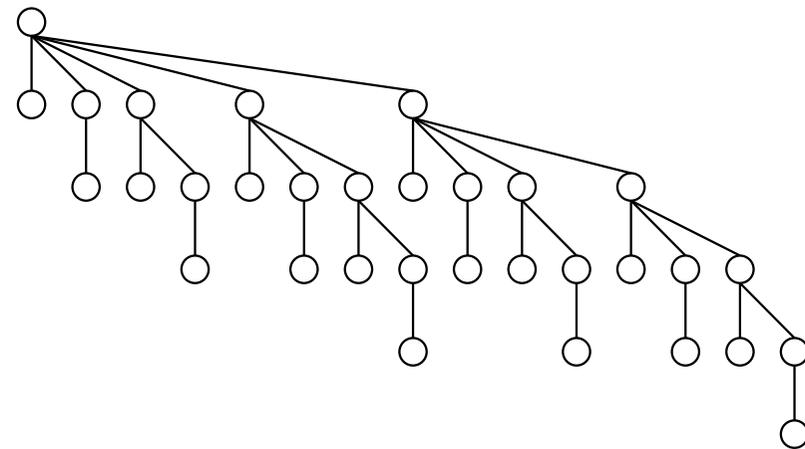
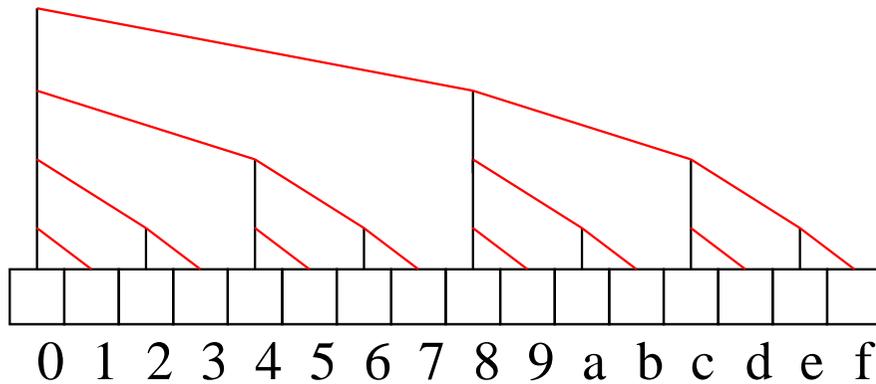
 // noop if receiver $\geq p$



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

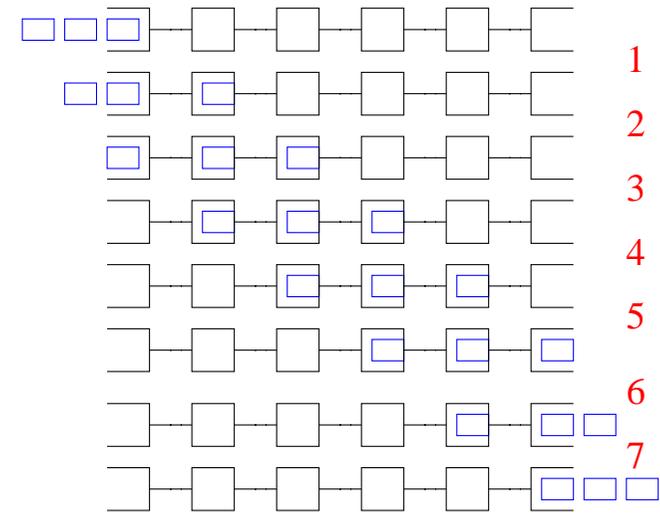
define **piece** j as $m[(j - 1)\frac{n}{k} + 1..j\frac{n}{k}]$

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 $j = 0$



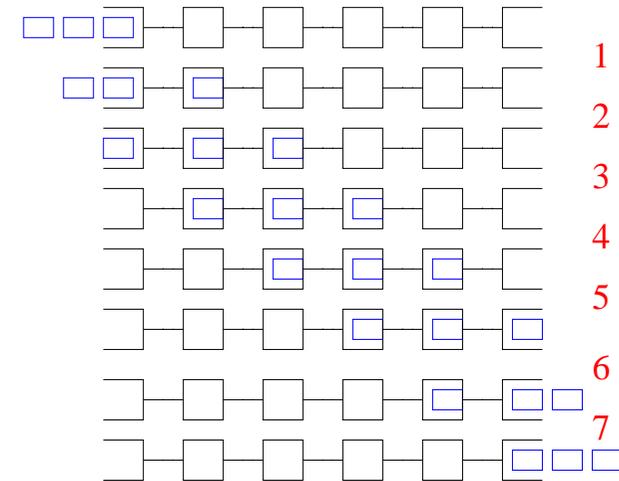
Analyse

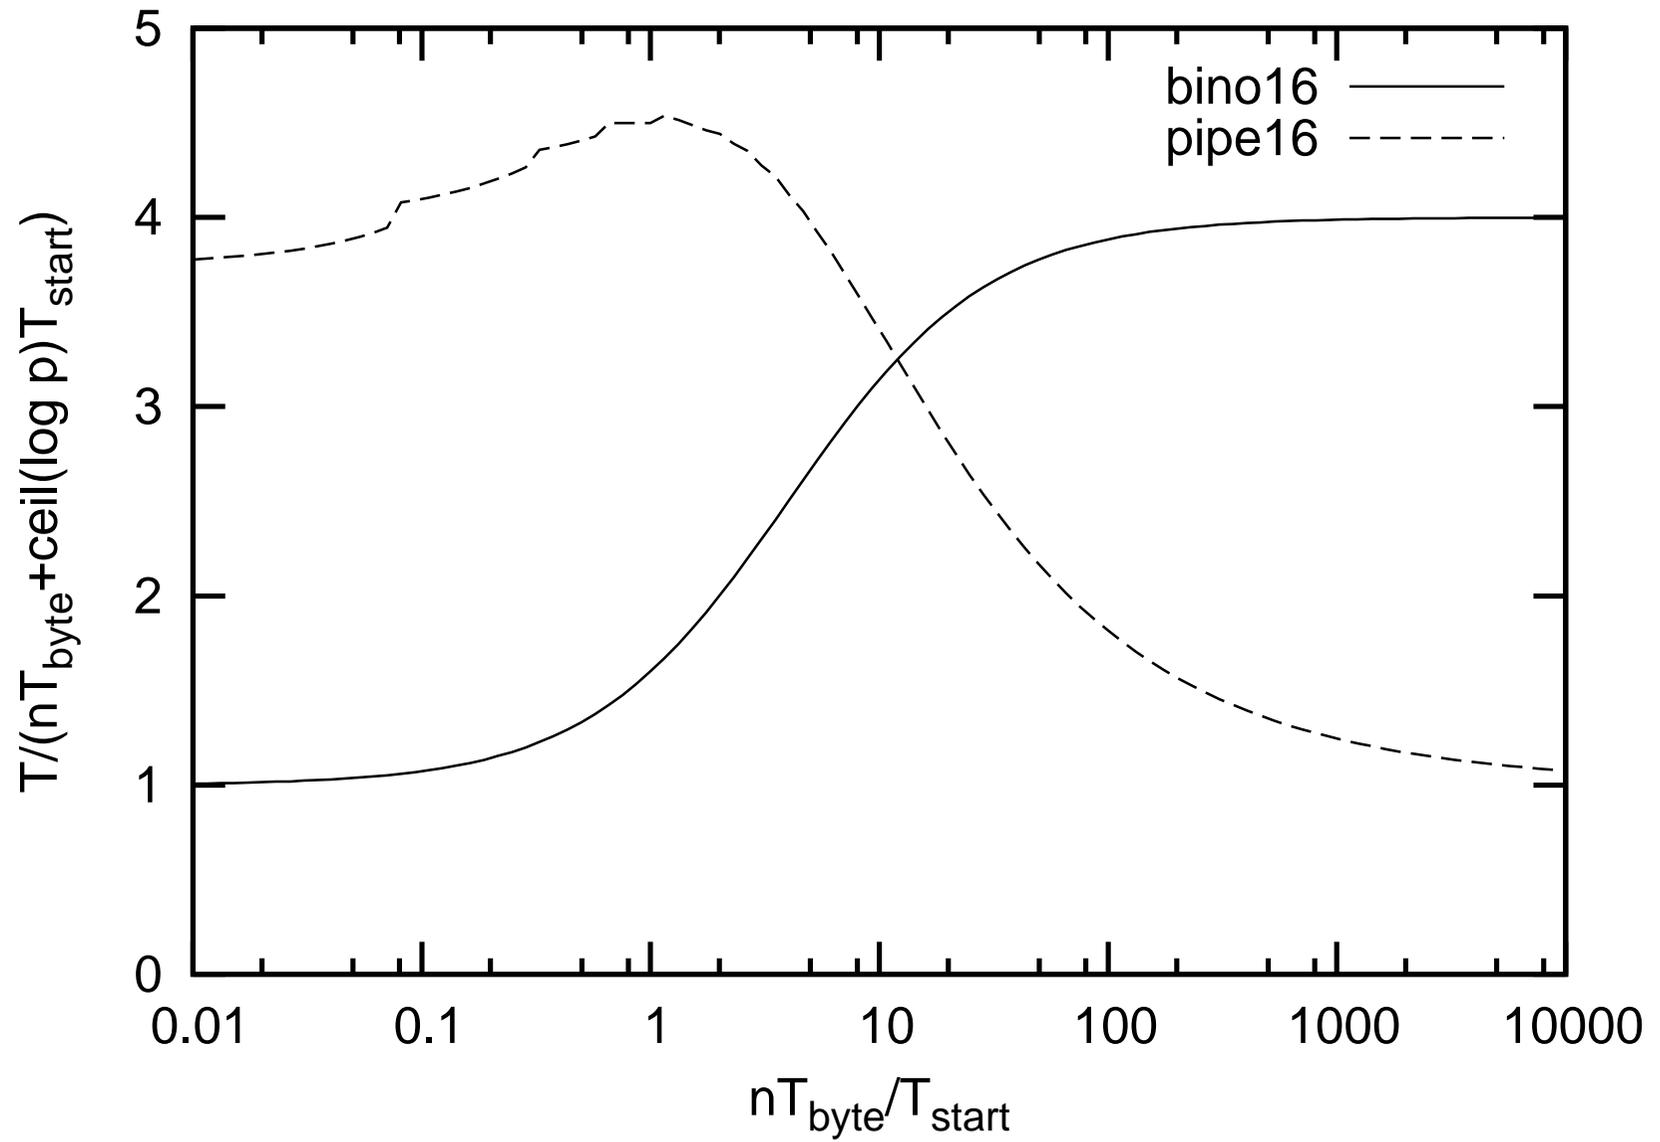
- Zeit $\frac{n}{k}T_{\text{byte}} + T_{\text{start}}$ pro Schritt
(\neq Iteration)
- $p - 1$ Schritte bis erstes Paket ankommt
- Dann 1 Schritte pro weiteres Paket

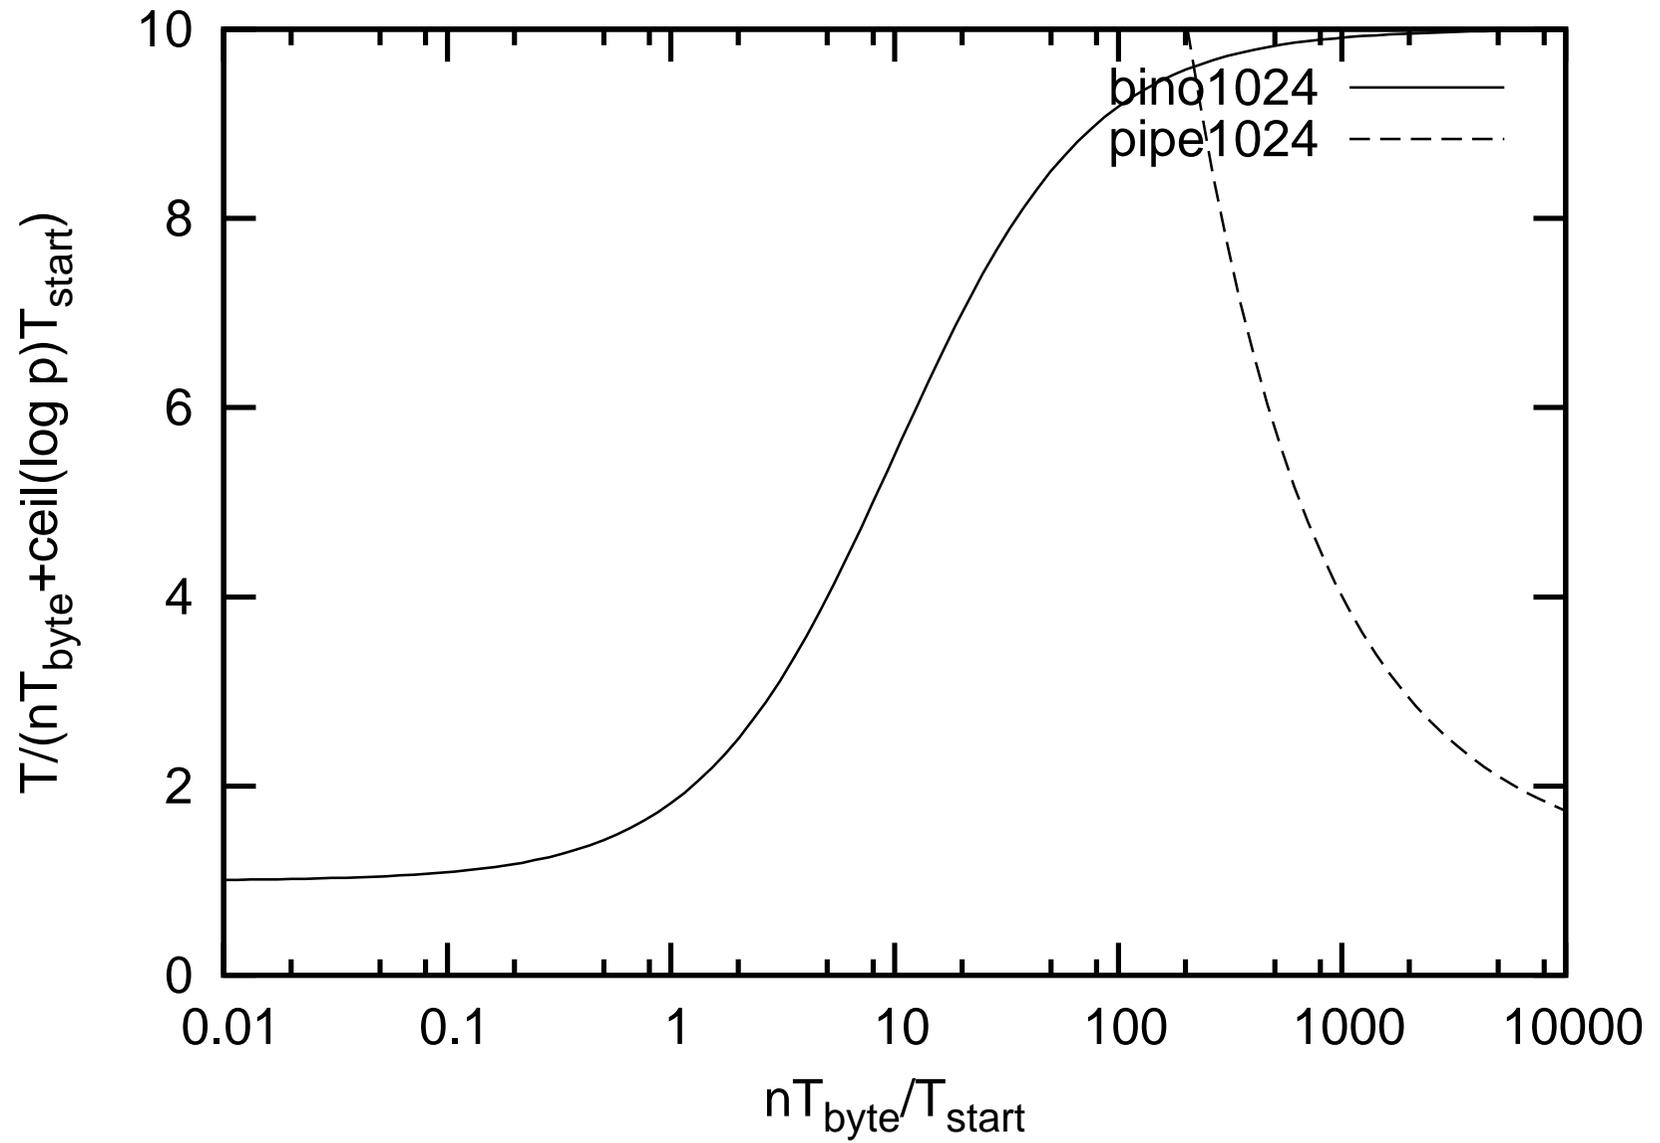
$$T(n, p, k): \left(\frac{n}{k}T_{\text{byte}} + T_{\text{start}} \right) (p + k - 2)$$

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

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







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

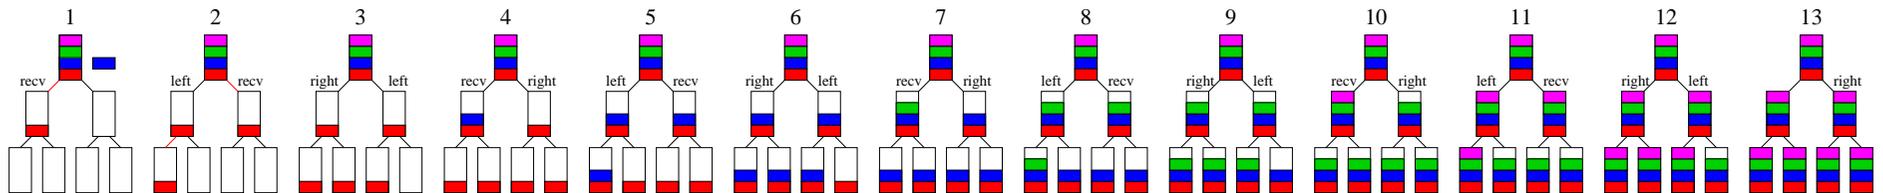
define **piece** j as $m[(j - 1)\frac{n}{k} + 1..j\frac{n}{k}]$

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

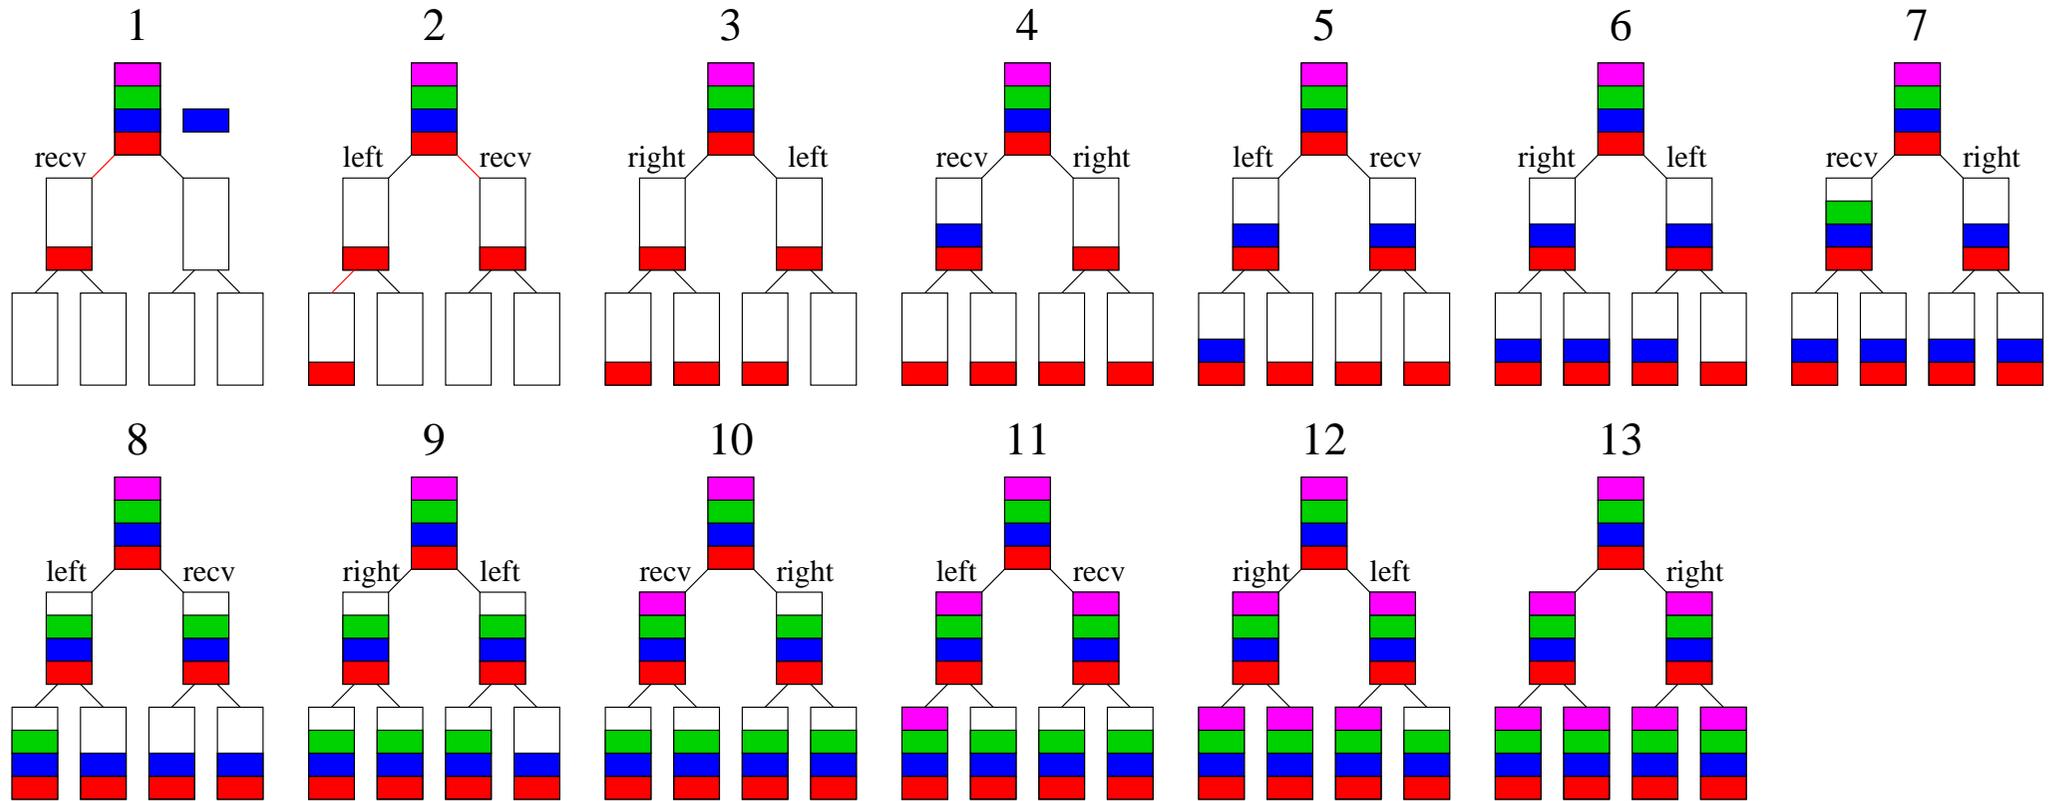
if **parent** exists **then** receive piece j

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)

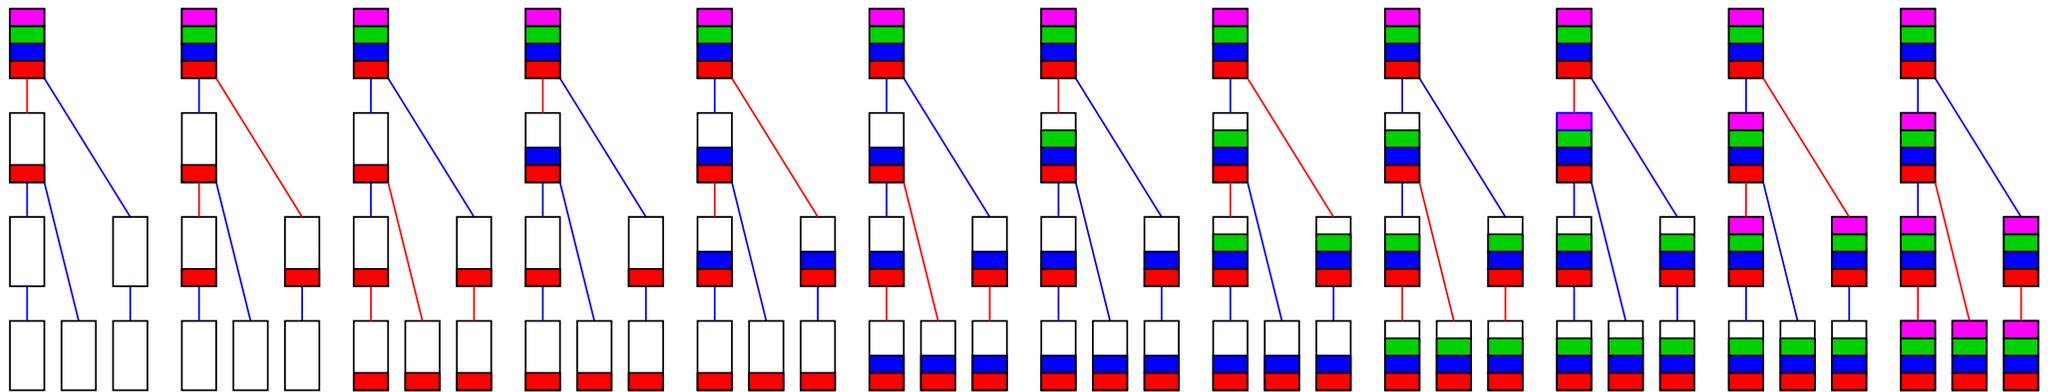
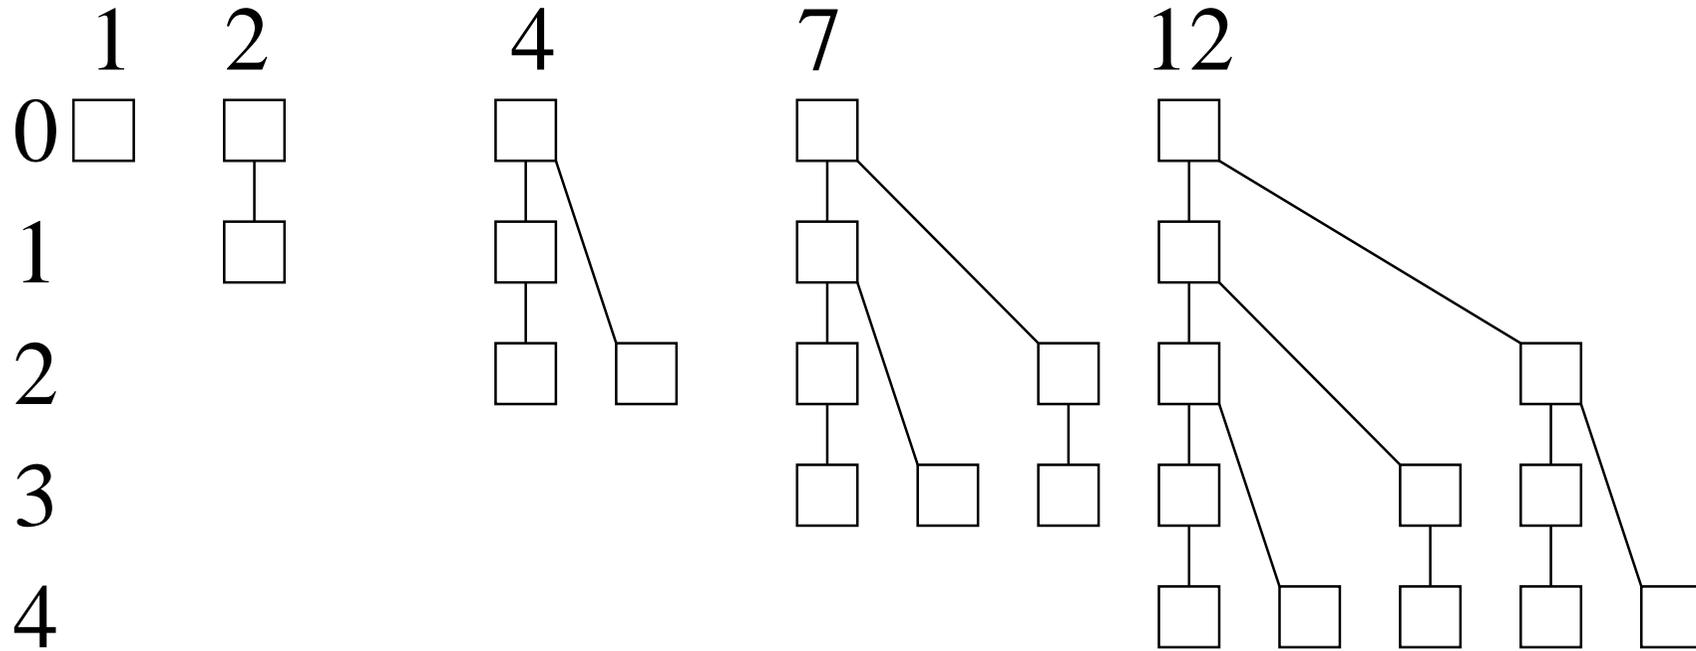
□ $d := \lfloor \log p \rfloor$ Schichten

□ 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



— active connection

— passive connection

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

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**

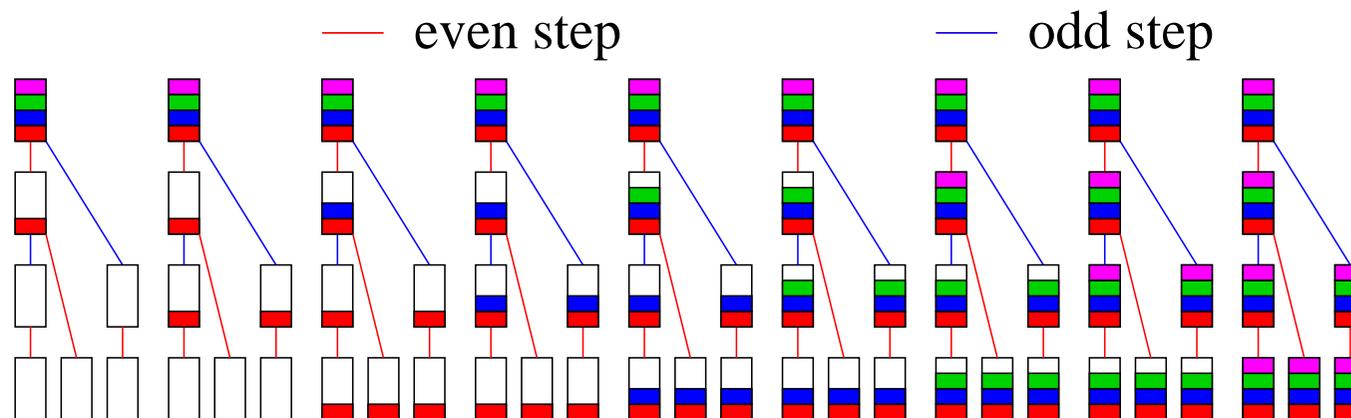
receive piece j from parent // noop for root or $j = k + 1$

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

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

send piece j to left child

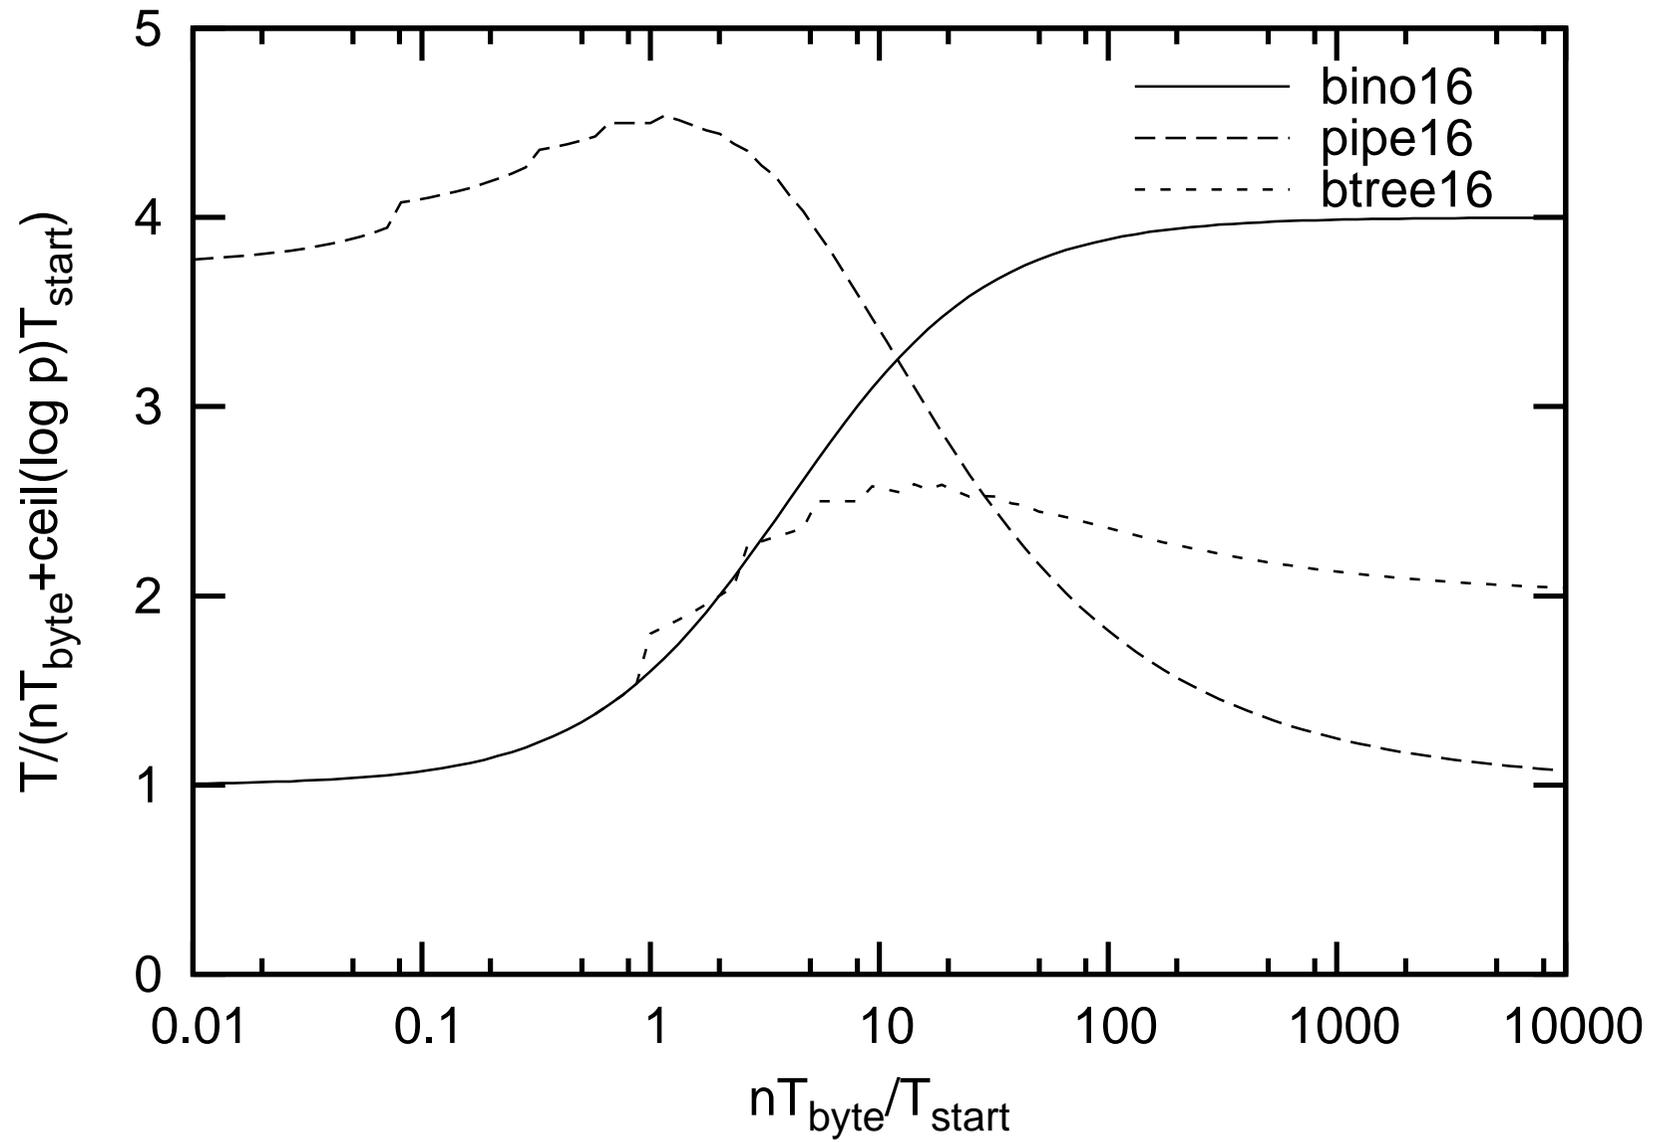
// noop if no such child or $j = k + 1$

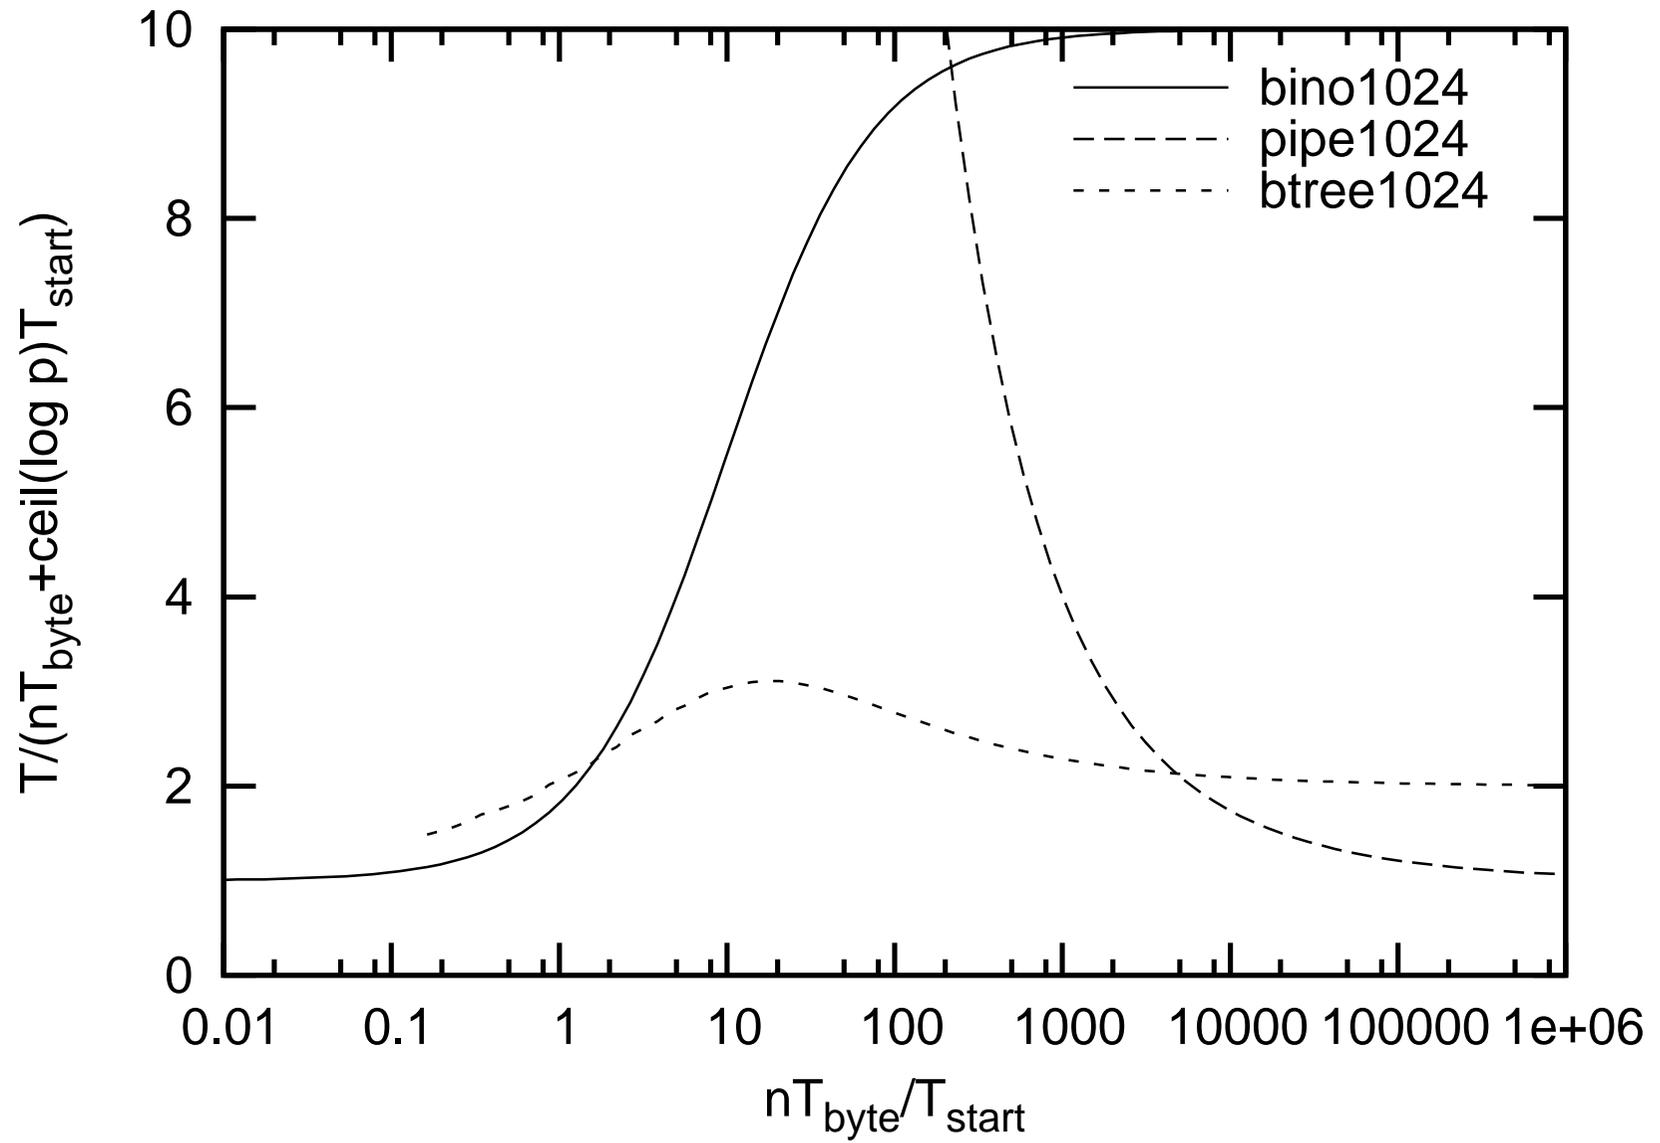


Analyse

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





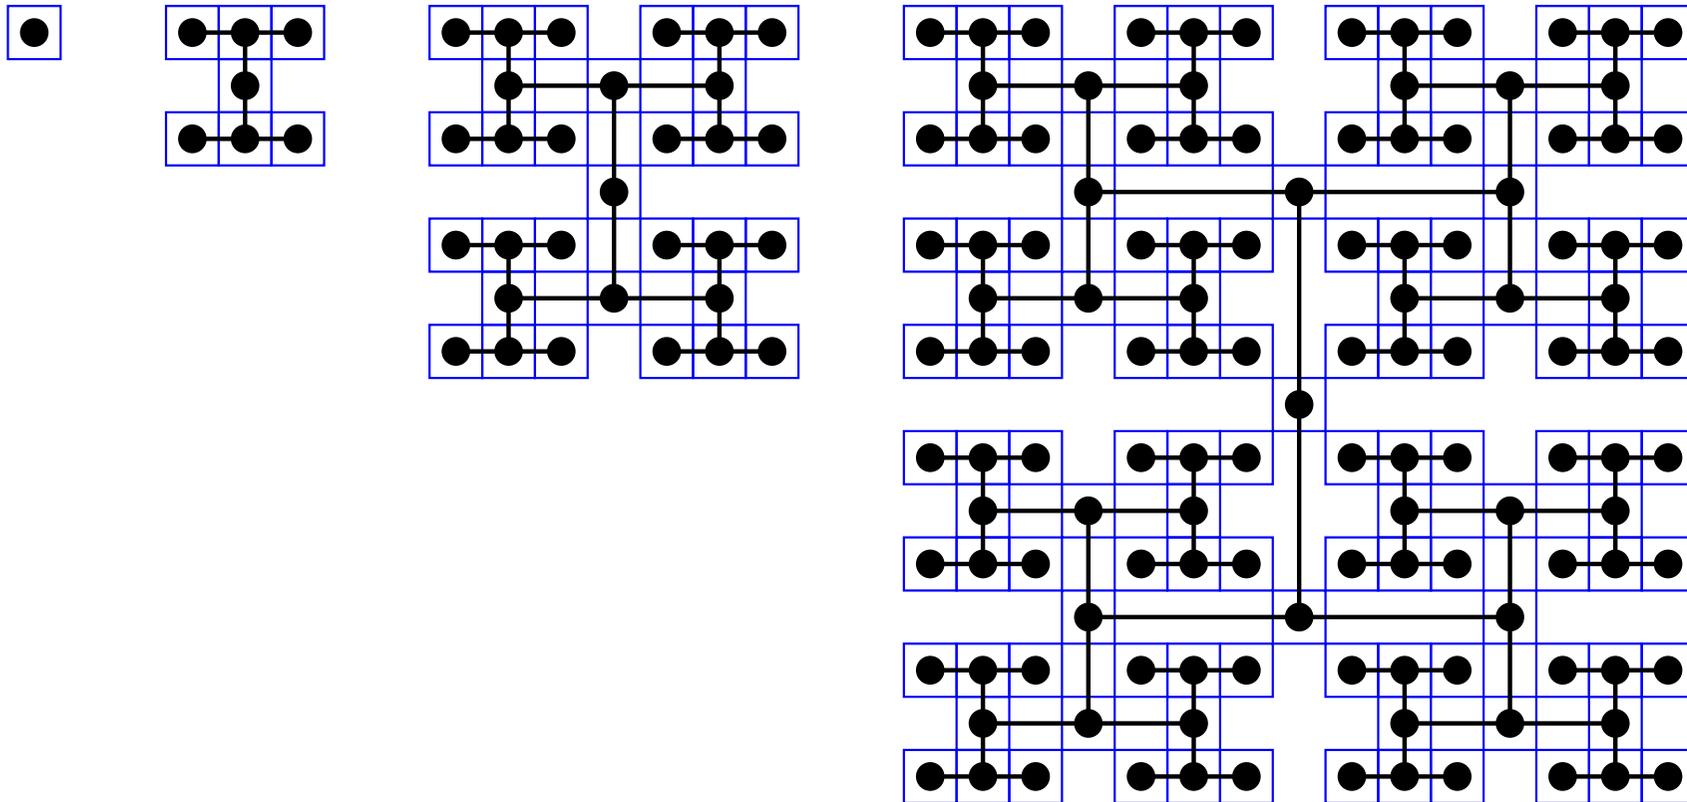
Diskussion

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

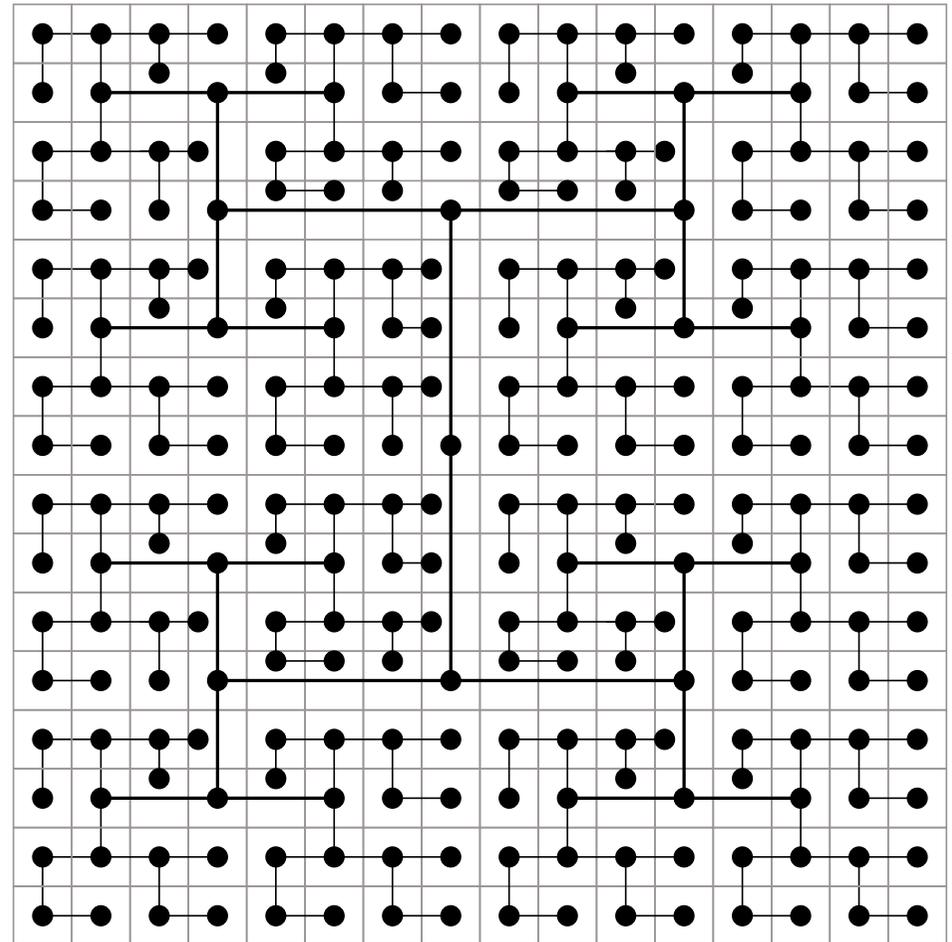
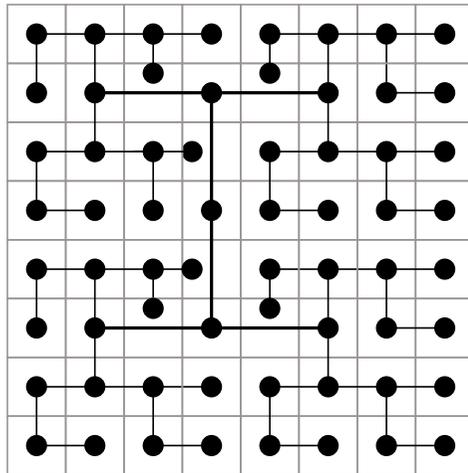
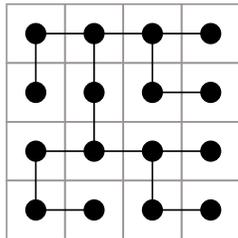
Allgemeine p :

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

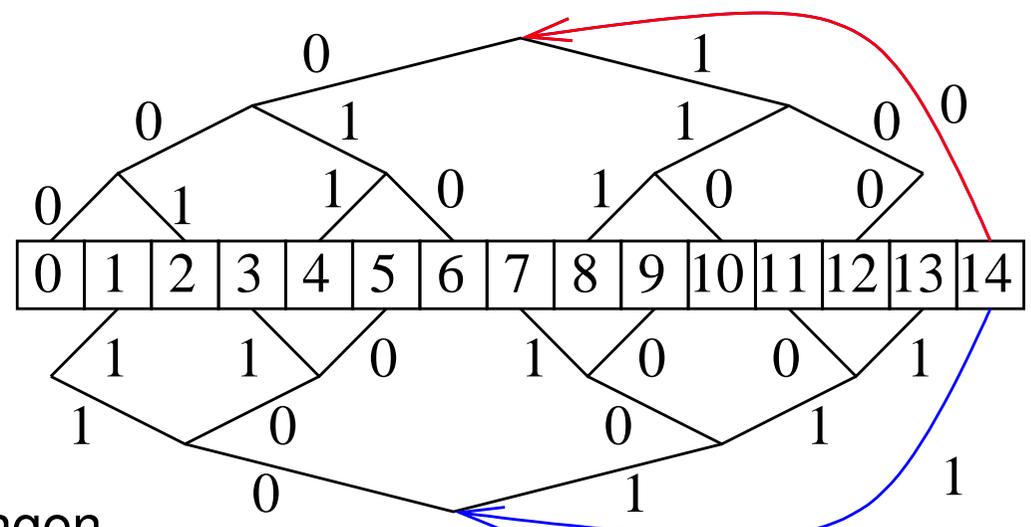
und umgekehrt

□ Pro Doppelschritt:

Ein Paket als Blatt empfangen +

Ein Paket als innerer Knoten empfangen und weiterleiten.

d.h. 2 Pakete senden und empfangen

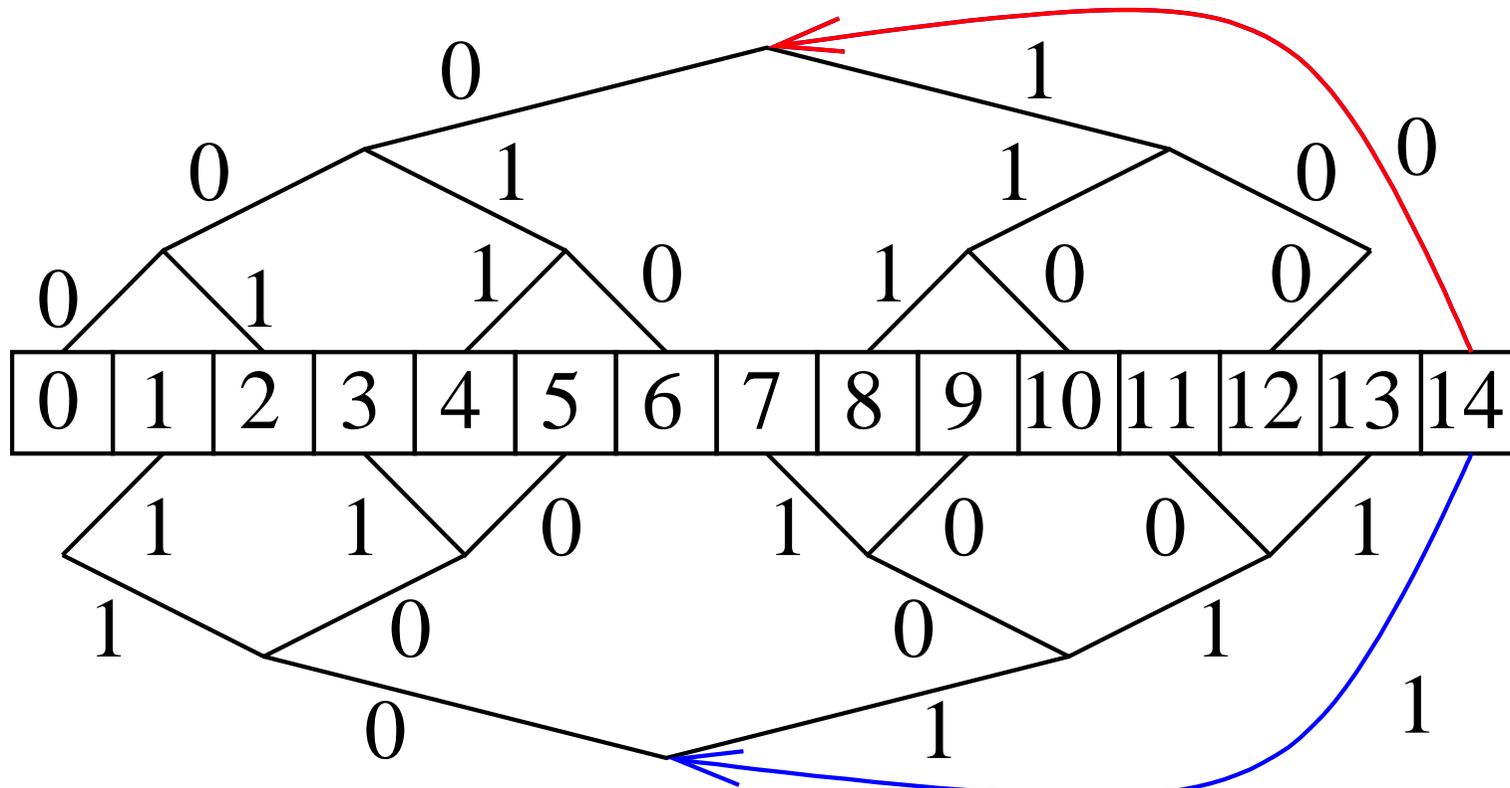


Root Process

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

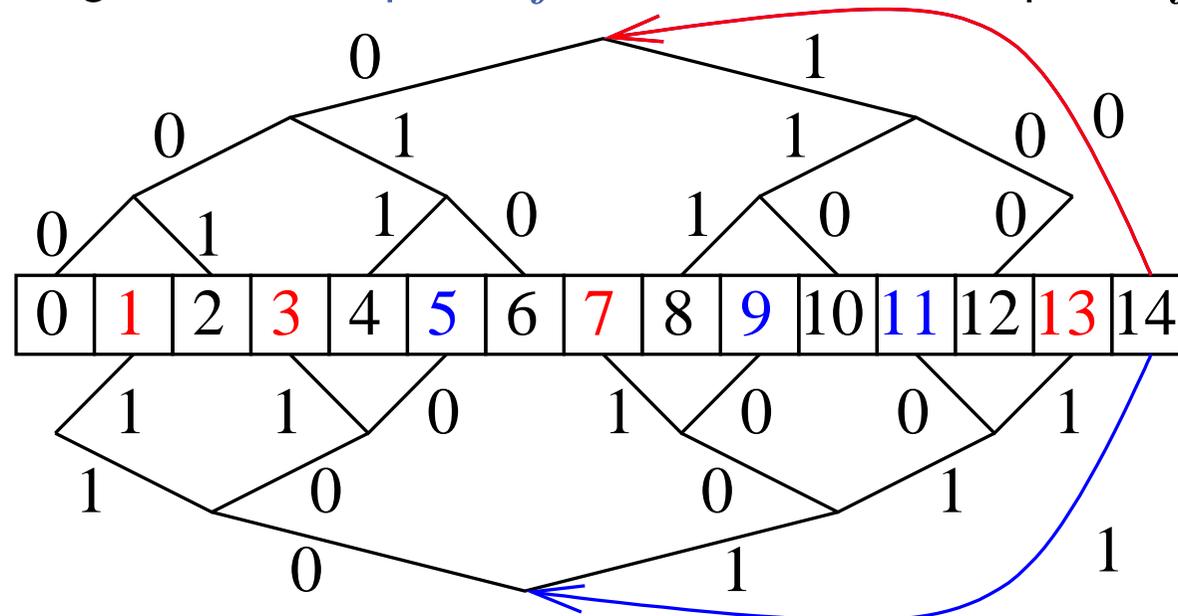
if it comes from the upper tree over an edge labelled *b* **then**

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

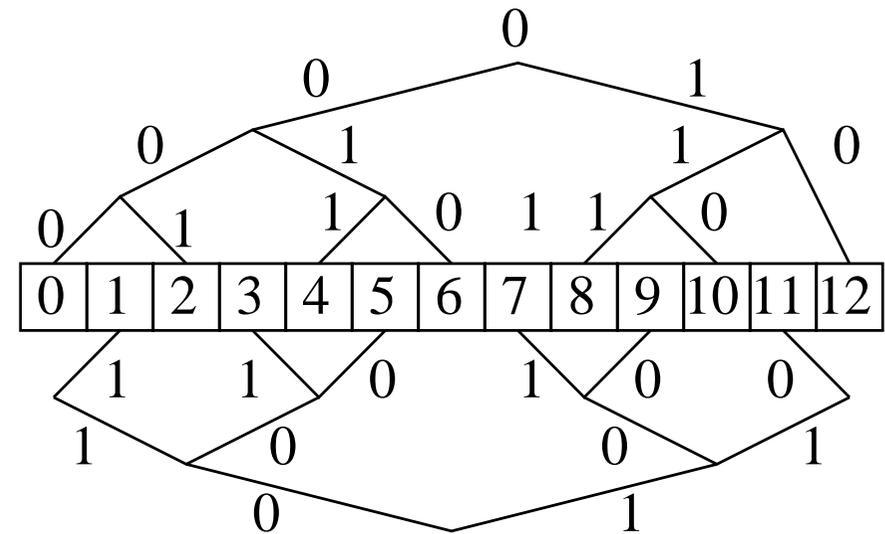
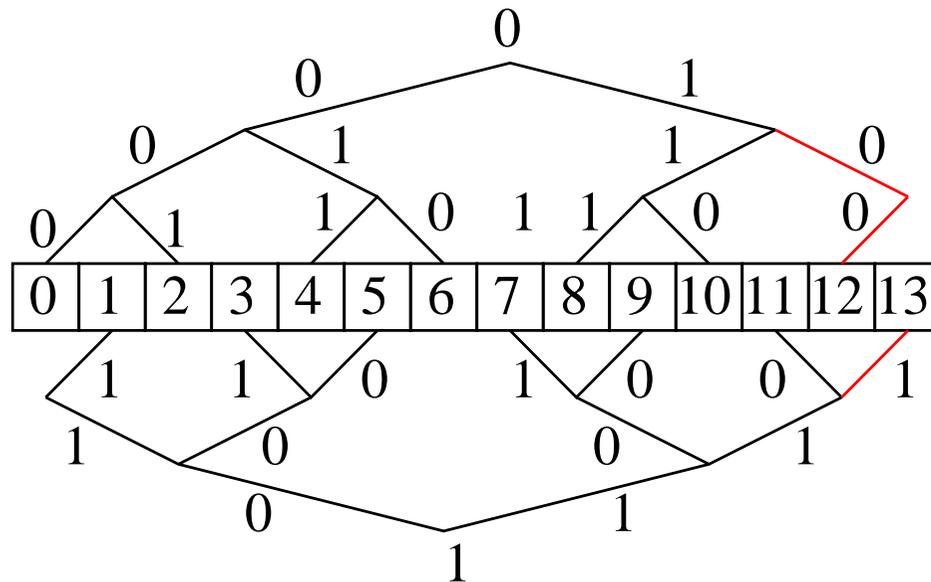
for $j := 1$ **to** $k + \Delta$ **step 2 do**

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

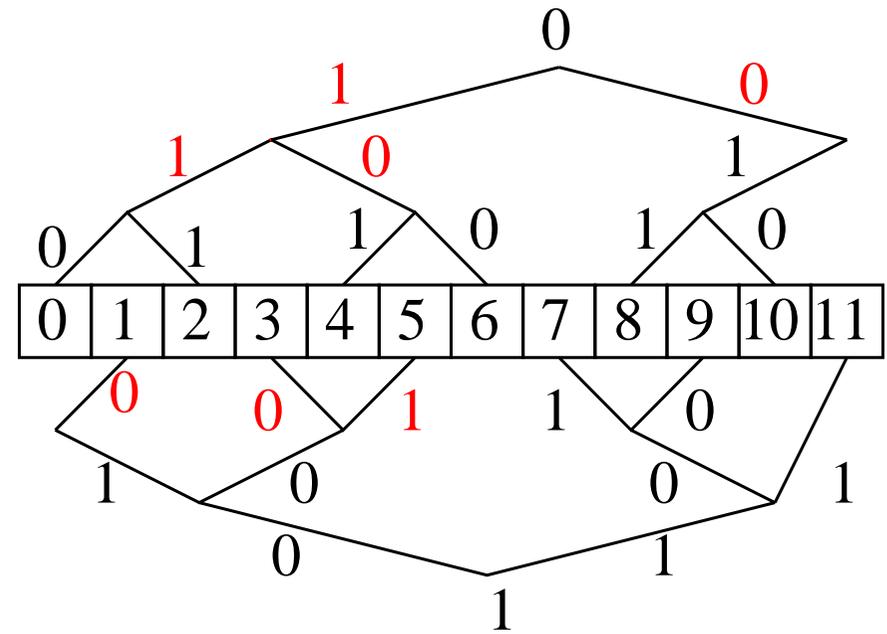
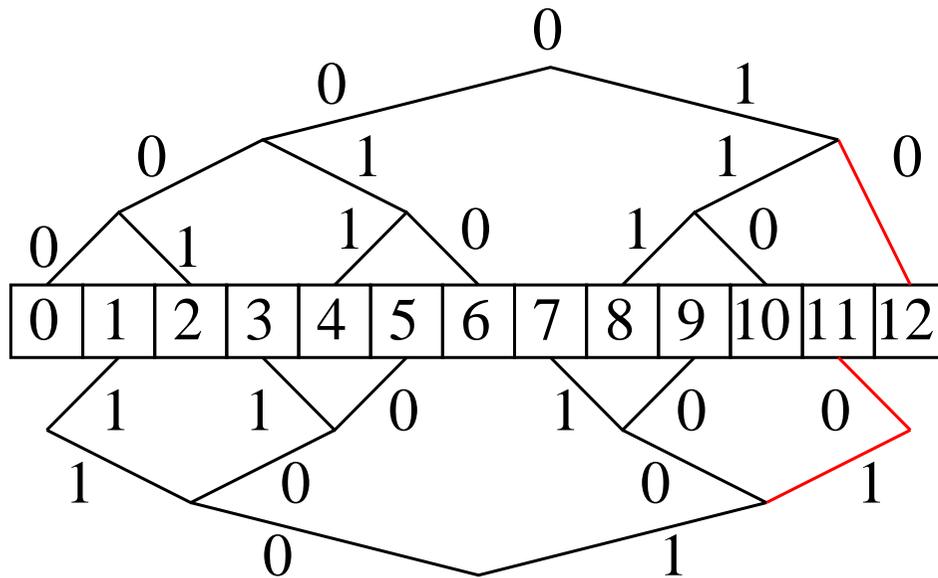
along $1 - b$ -edges: receive piece $j + 1 - \Delta$ and send piece j



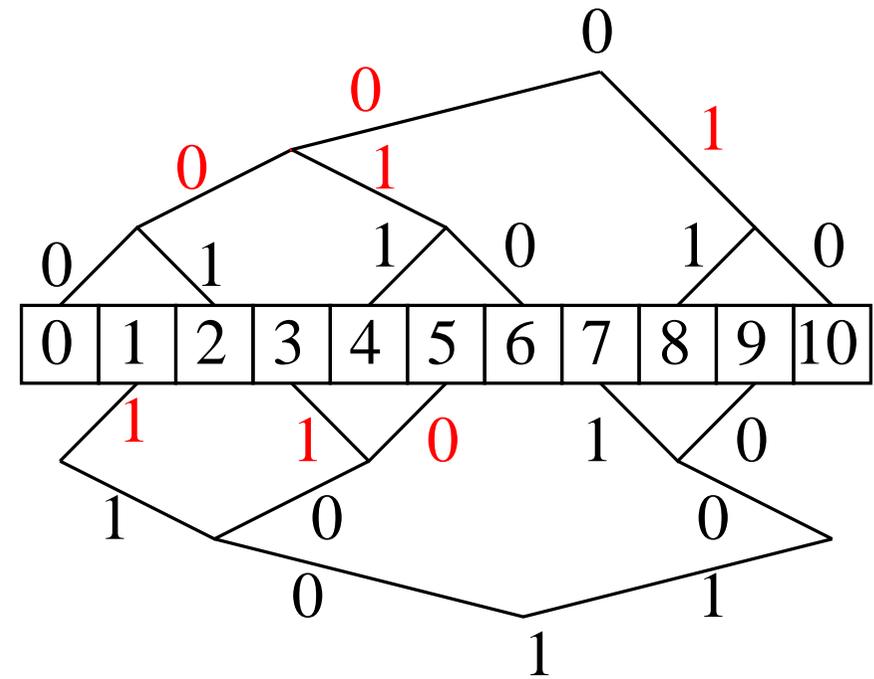
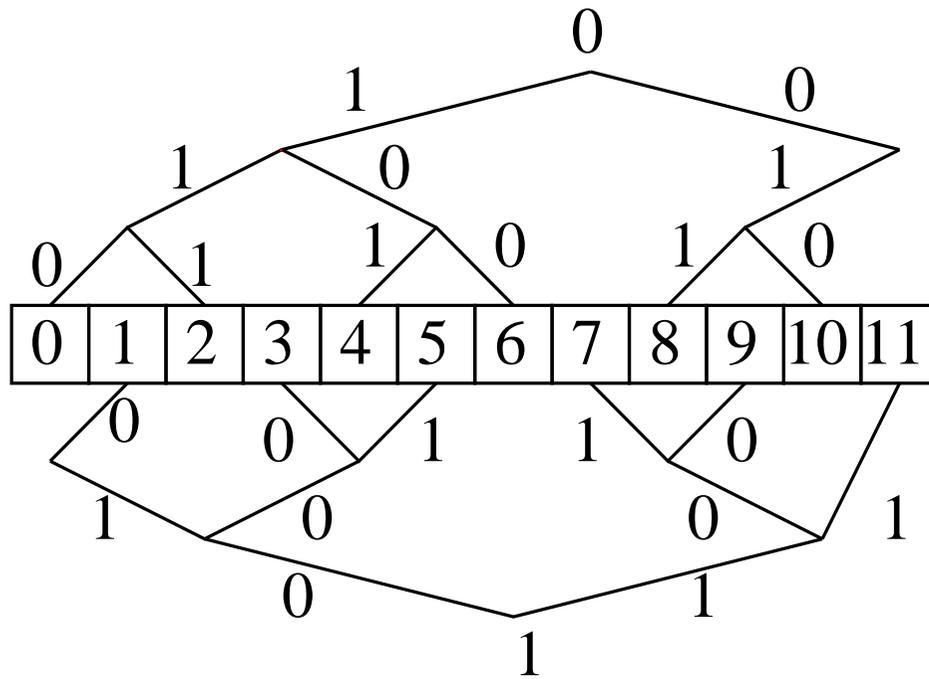
Beliebige Prozessorzahl



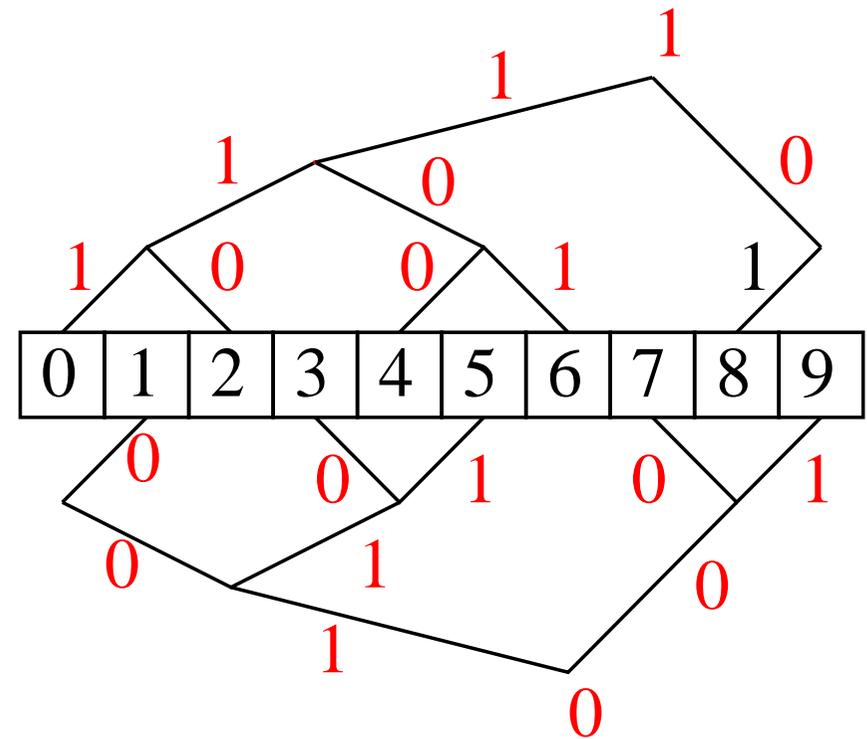
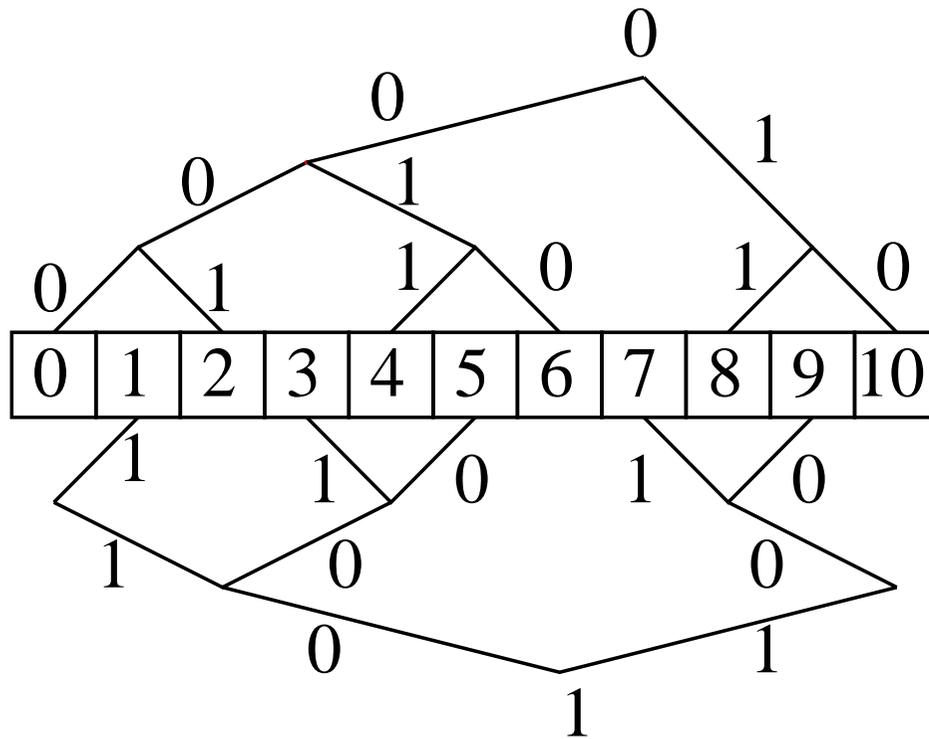
Beliebige Prozessorzahl



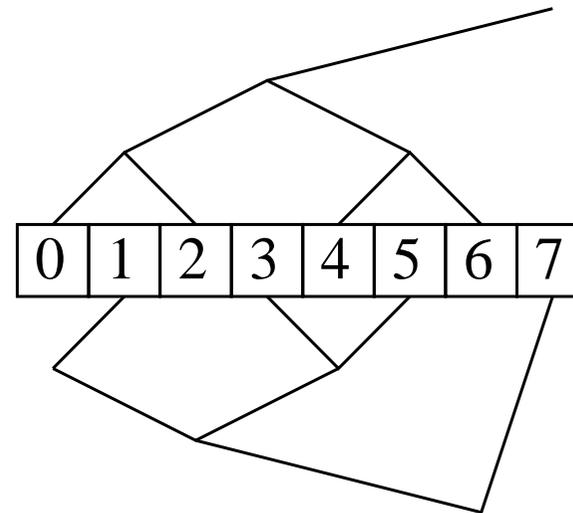
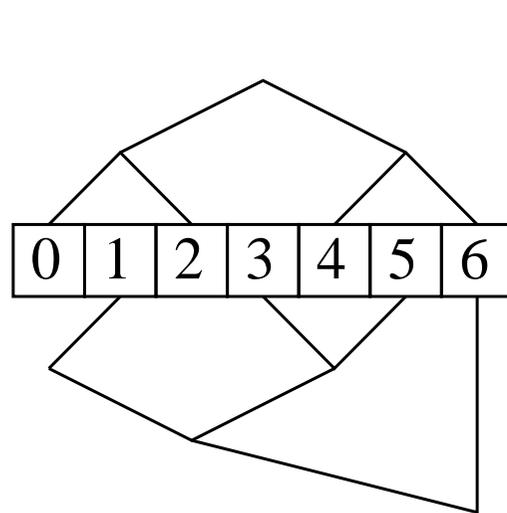
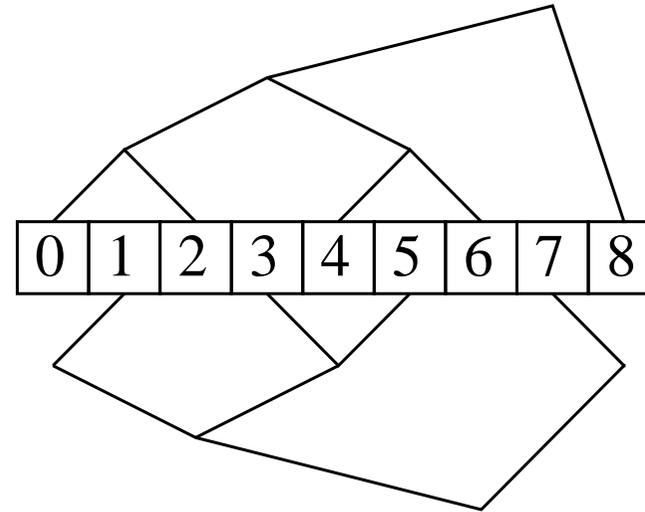
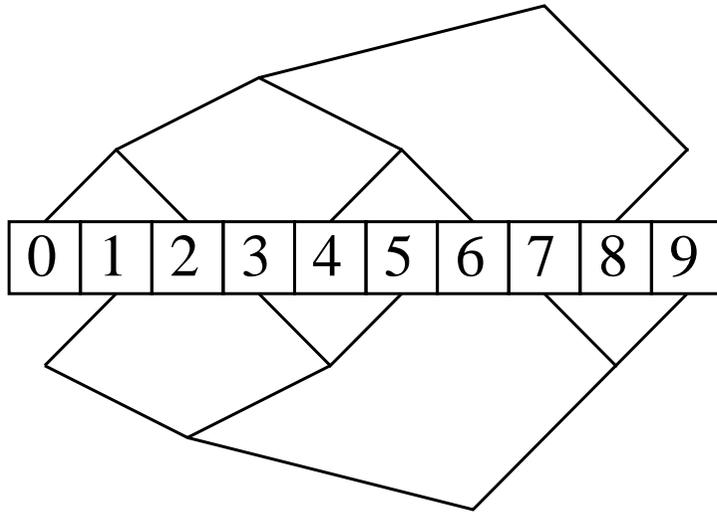
Beliebige Prozessorzahl



Beliebige Prozessorzahl



Beliebige Prozessorzahl



Aufbau der Bäume

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

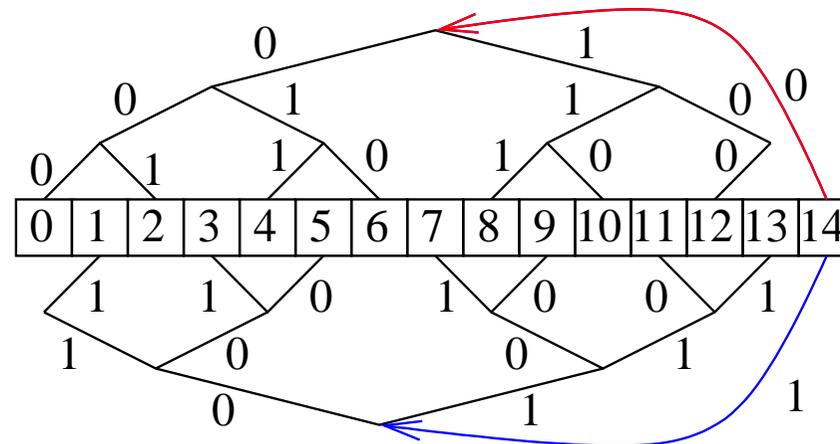
Oberer Baum: Vollst. Binärbaum der Höhe $h - 1$, – **rechtes** Blatt

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.



Kanten färben

Betrachte den bipartiten Graphen

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

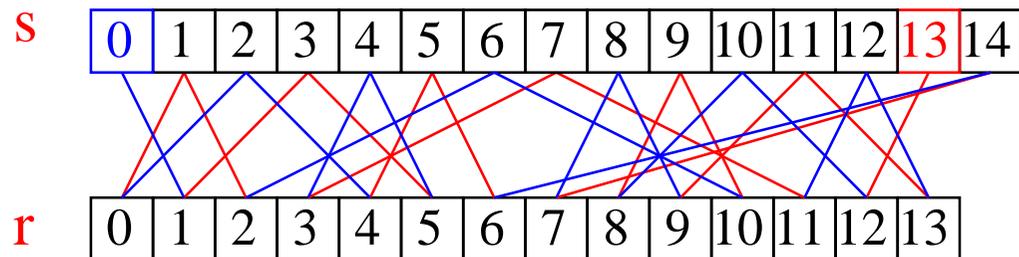
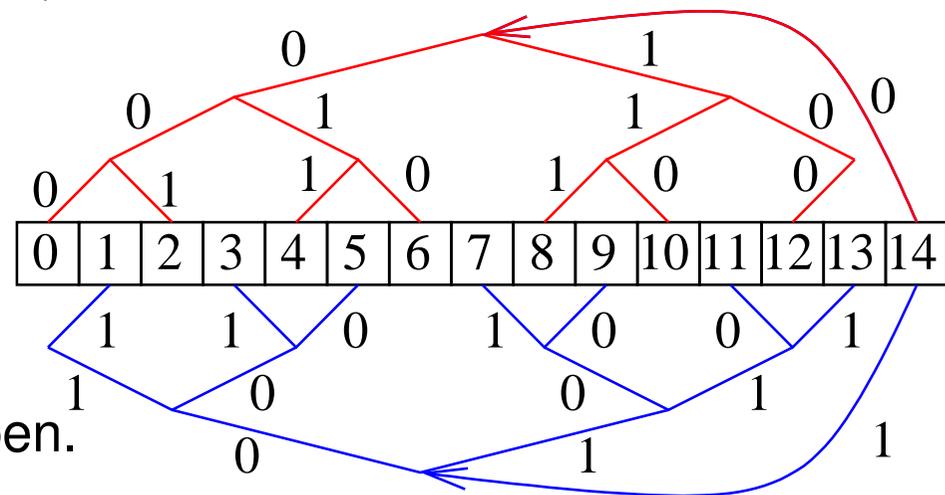
s_i : Senderrolle von PE i .

r_i : Empfängerrolle von PE i .

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

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

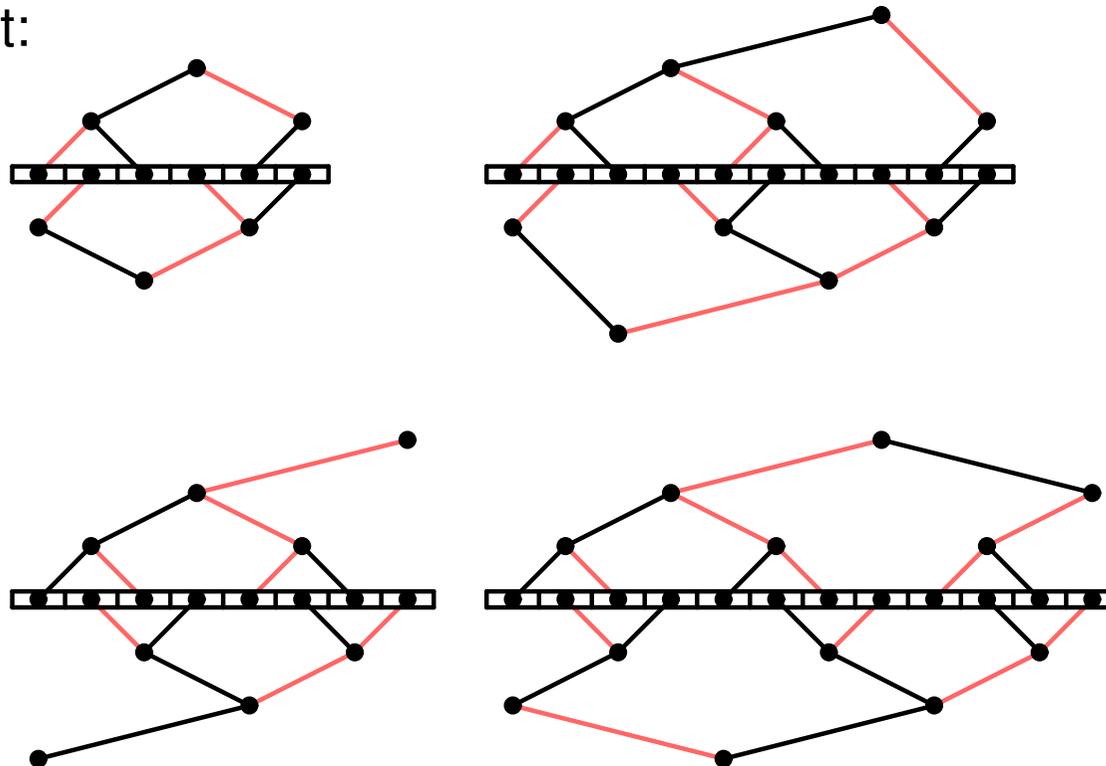
Kanten abwechselnd mit 0 und 1 färben.



Offene Frage: **Parallele 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 $i \text{ bitand } 2^h = 0$ **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 [$i' > i$]

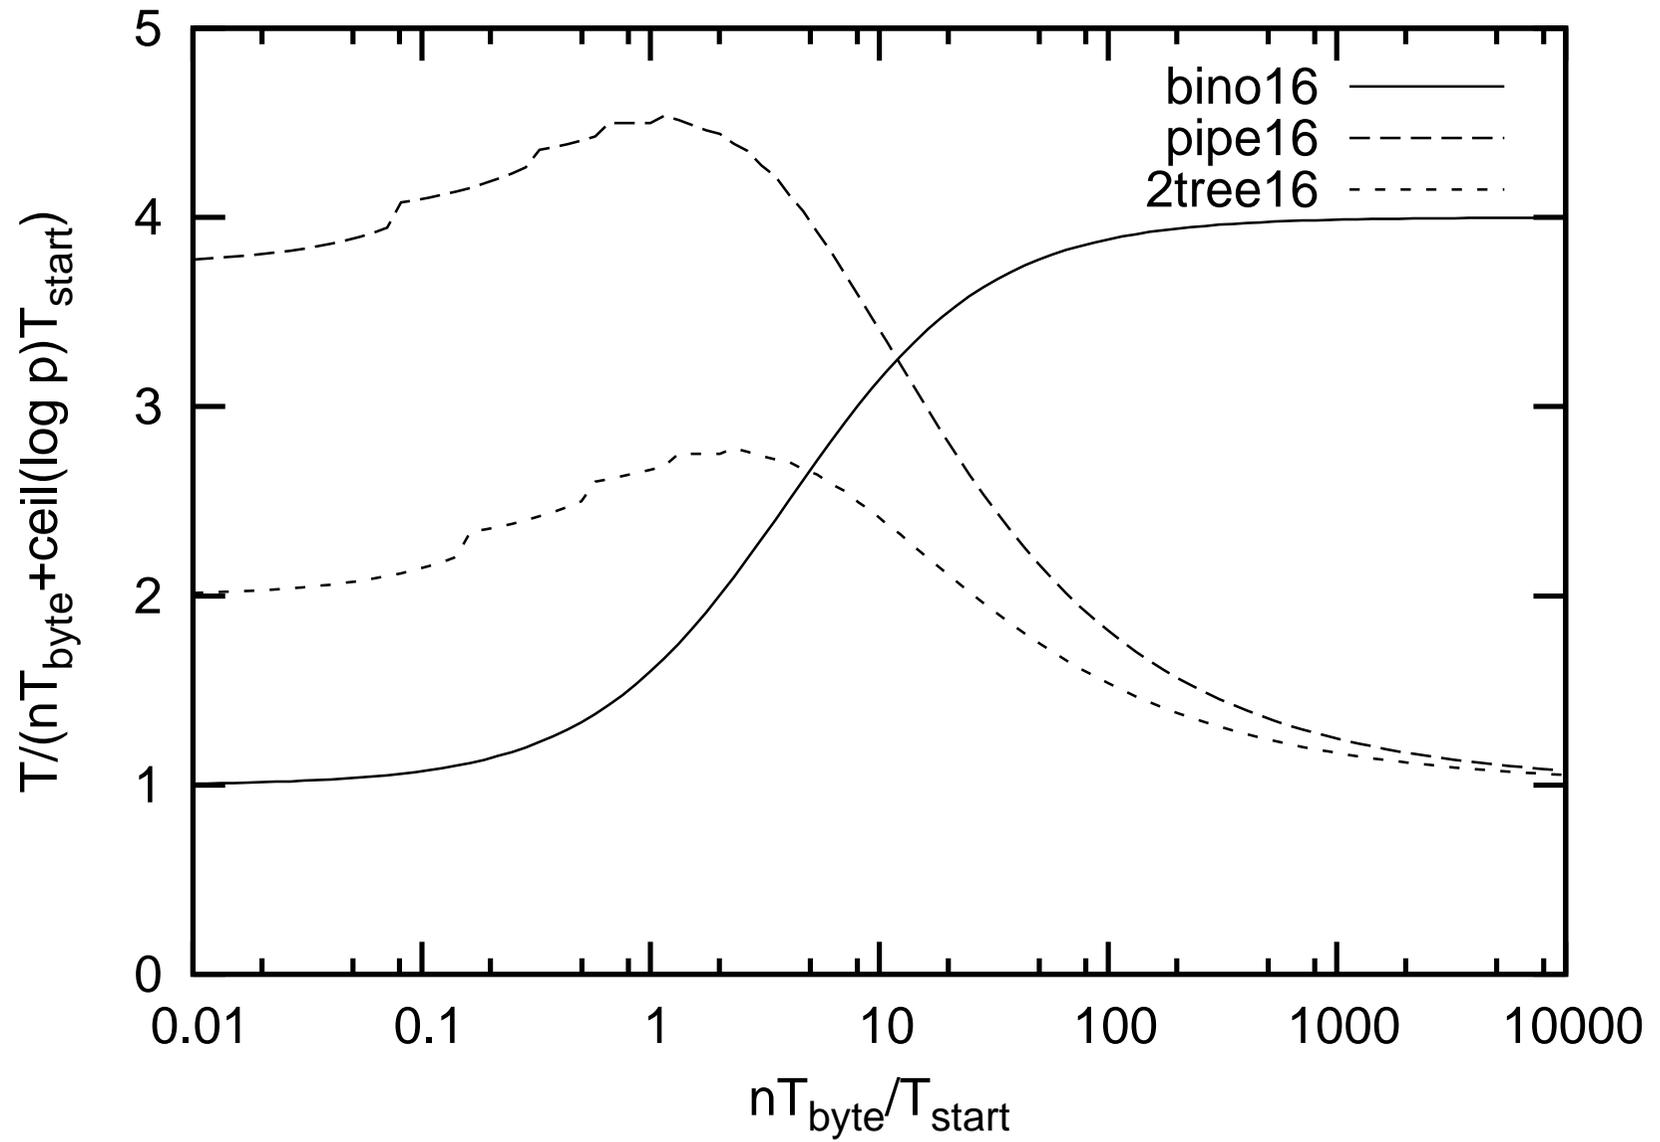
Analyse

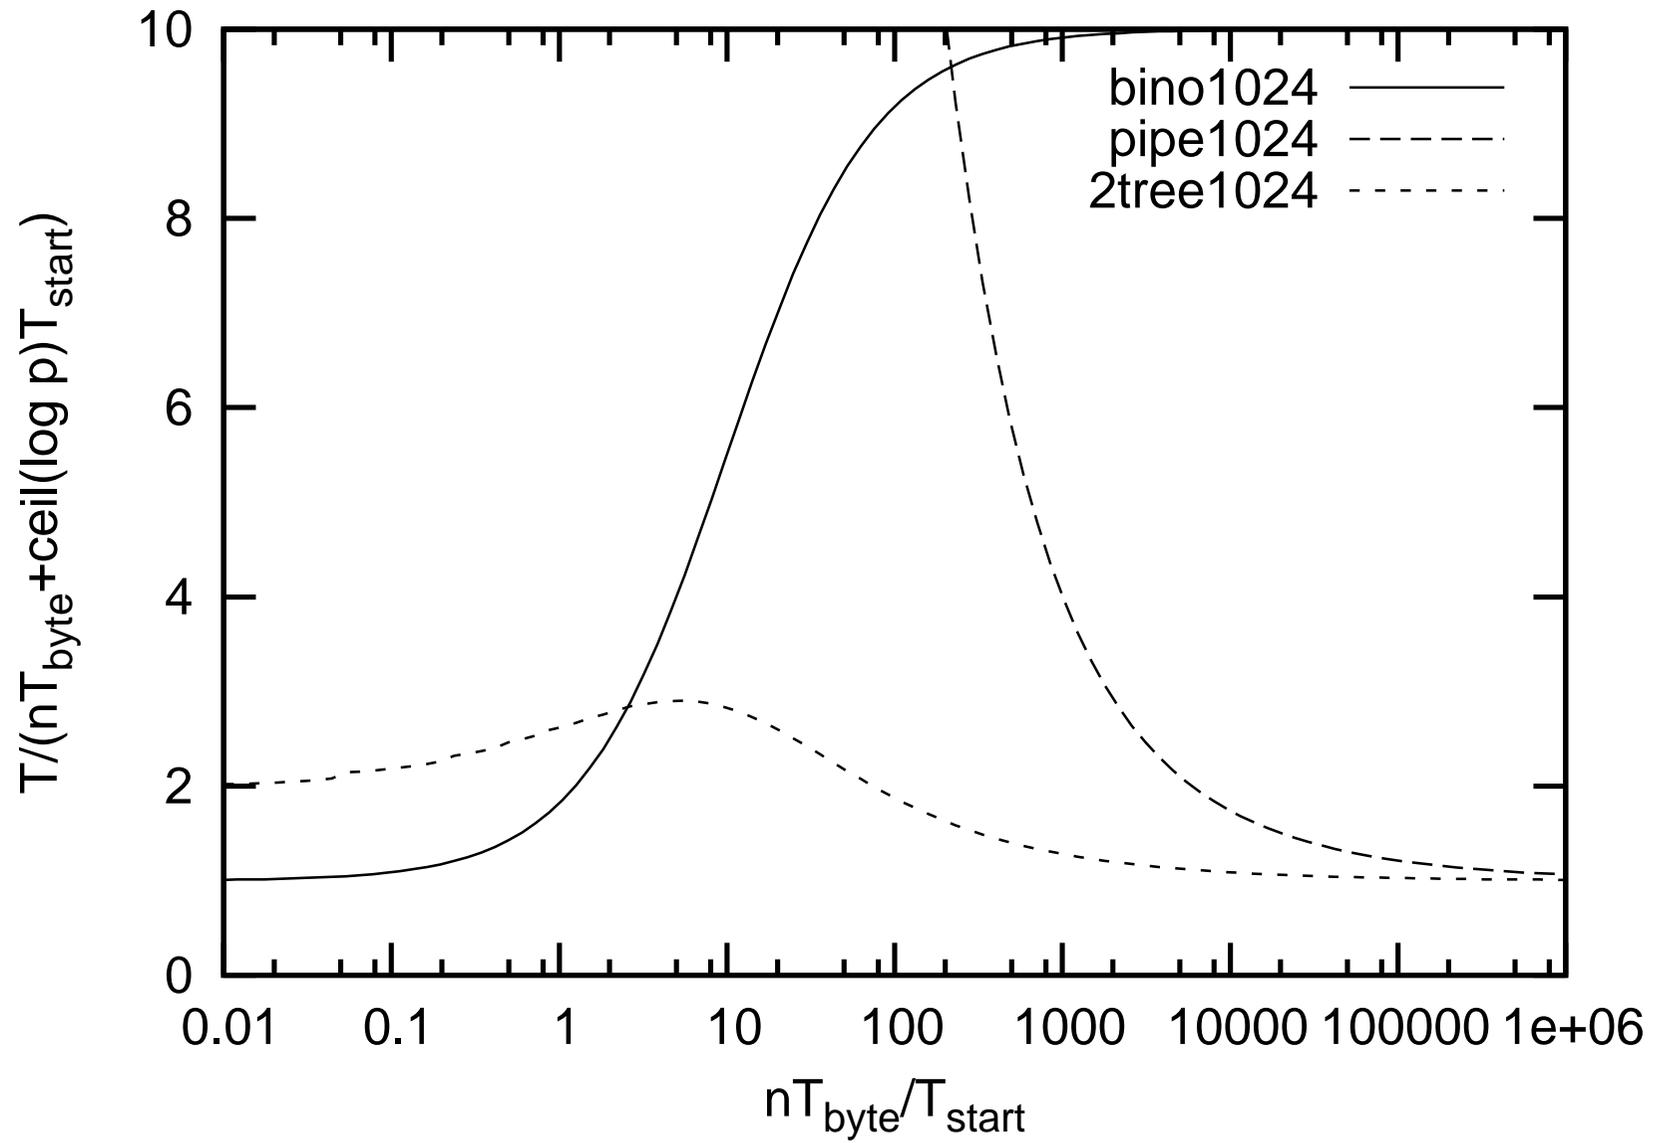
- Zeit $\frac{n}{k}T_{\text{byte}} + T_{\text{start}}$ pro Schritt
- $2j$ Schritte bis alle PEs in Schicht j erreicht
- $d = \lceil \log(p + 1) \rceil$ Schichten
- Dann 2 Schritte pro weitere 2 Pakete

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

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

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

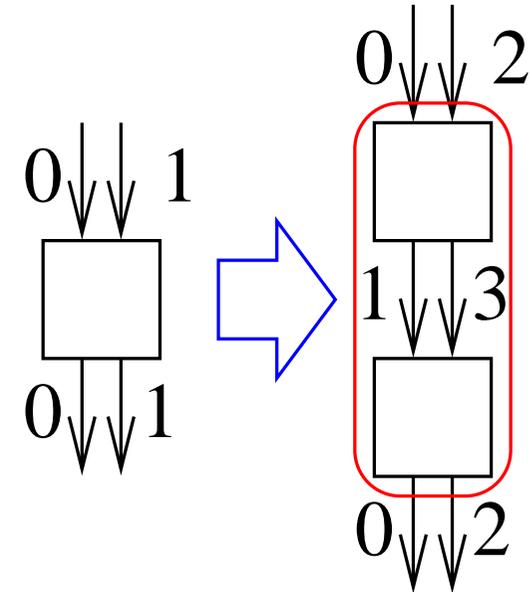




Implementierung im Simplex-Modell

2 Zeitschritt duplex \rightsquigarrow 4 Zeitschritt simplex.

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



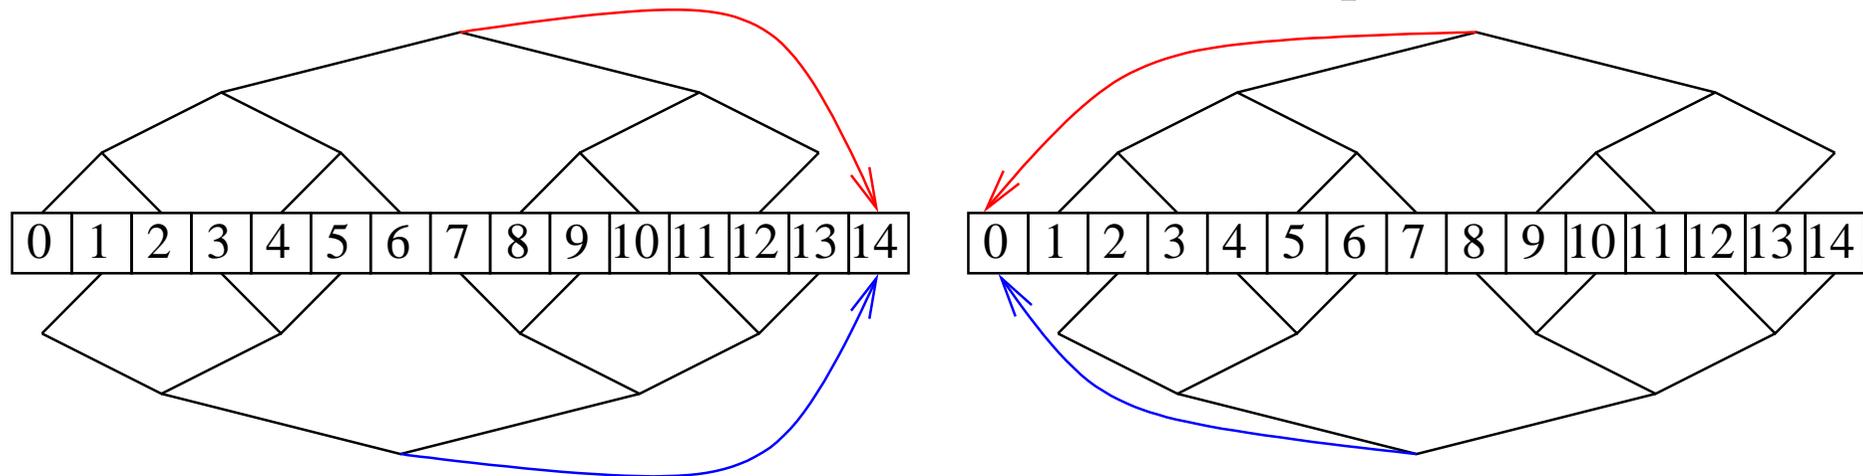
Offene Frage:

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

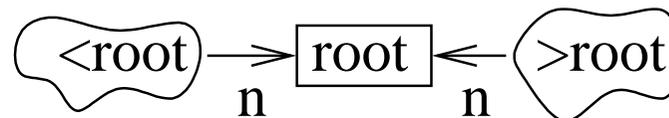
23-Reduktion

Nummerierung ist Inorder-Nummerierung für beide Bäume !

kommutativ oder $root=0$ oder $root=p-1$:



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.]

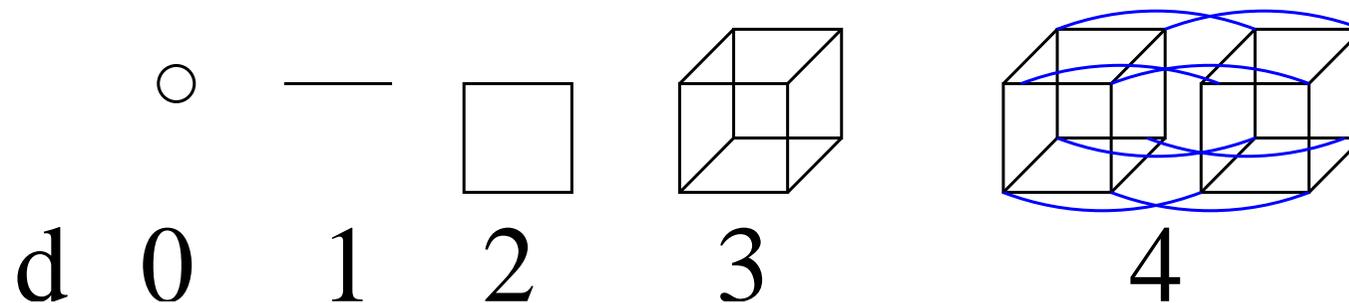
Idee: getrennt marschieren — vereint schlagen

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

Anpassung halb-duplex: alles $\times 2$

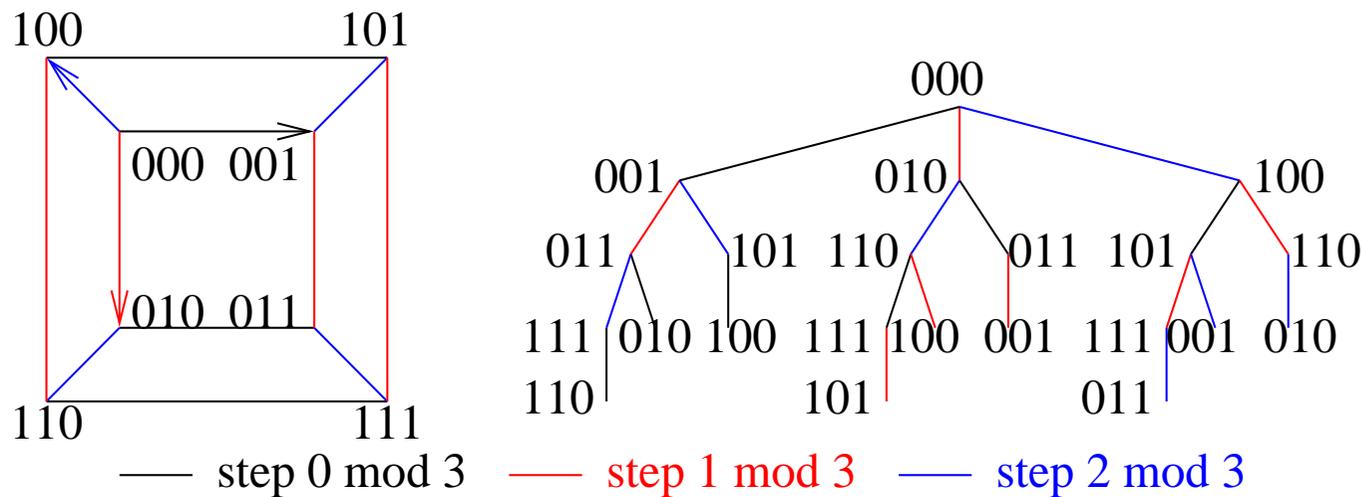
Hyperwürfel H_d

- $p = 2^d$ 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)



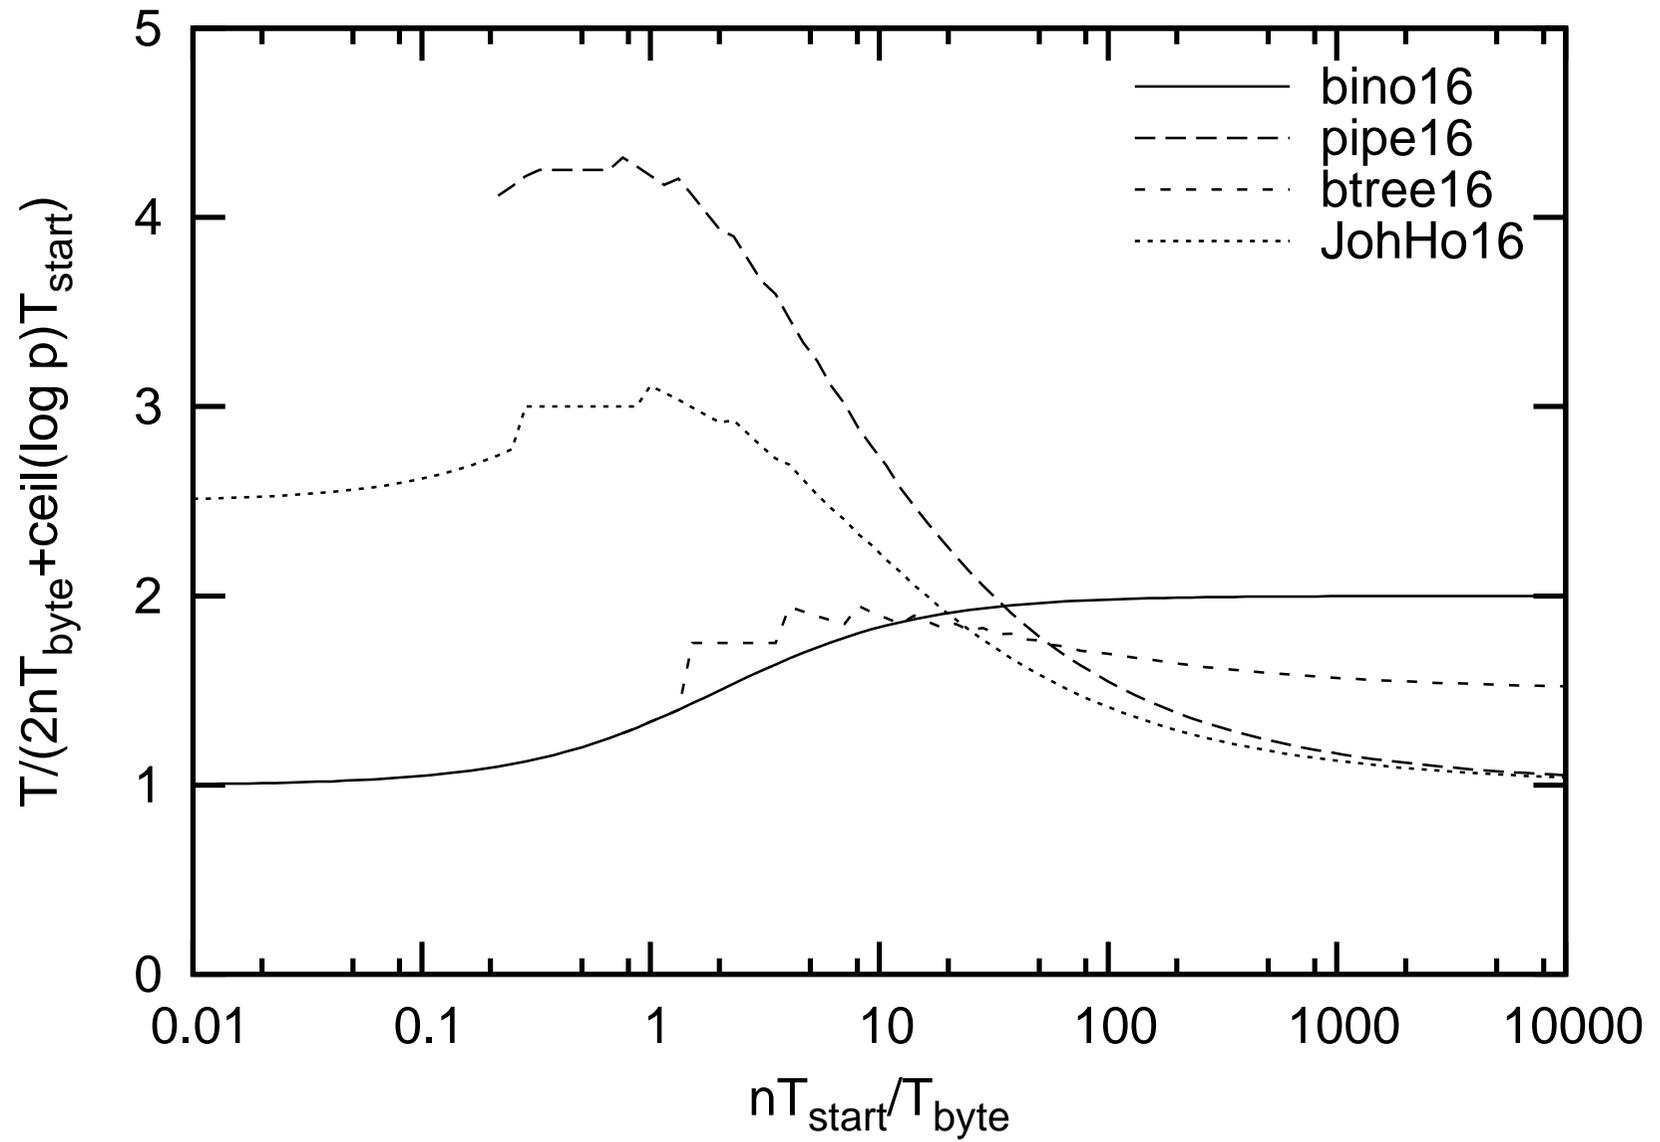
Analyse, Telefonmodell

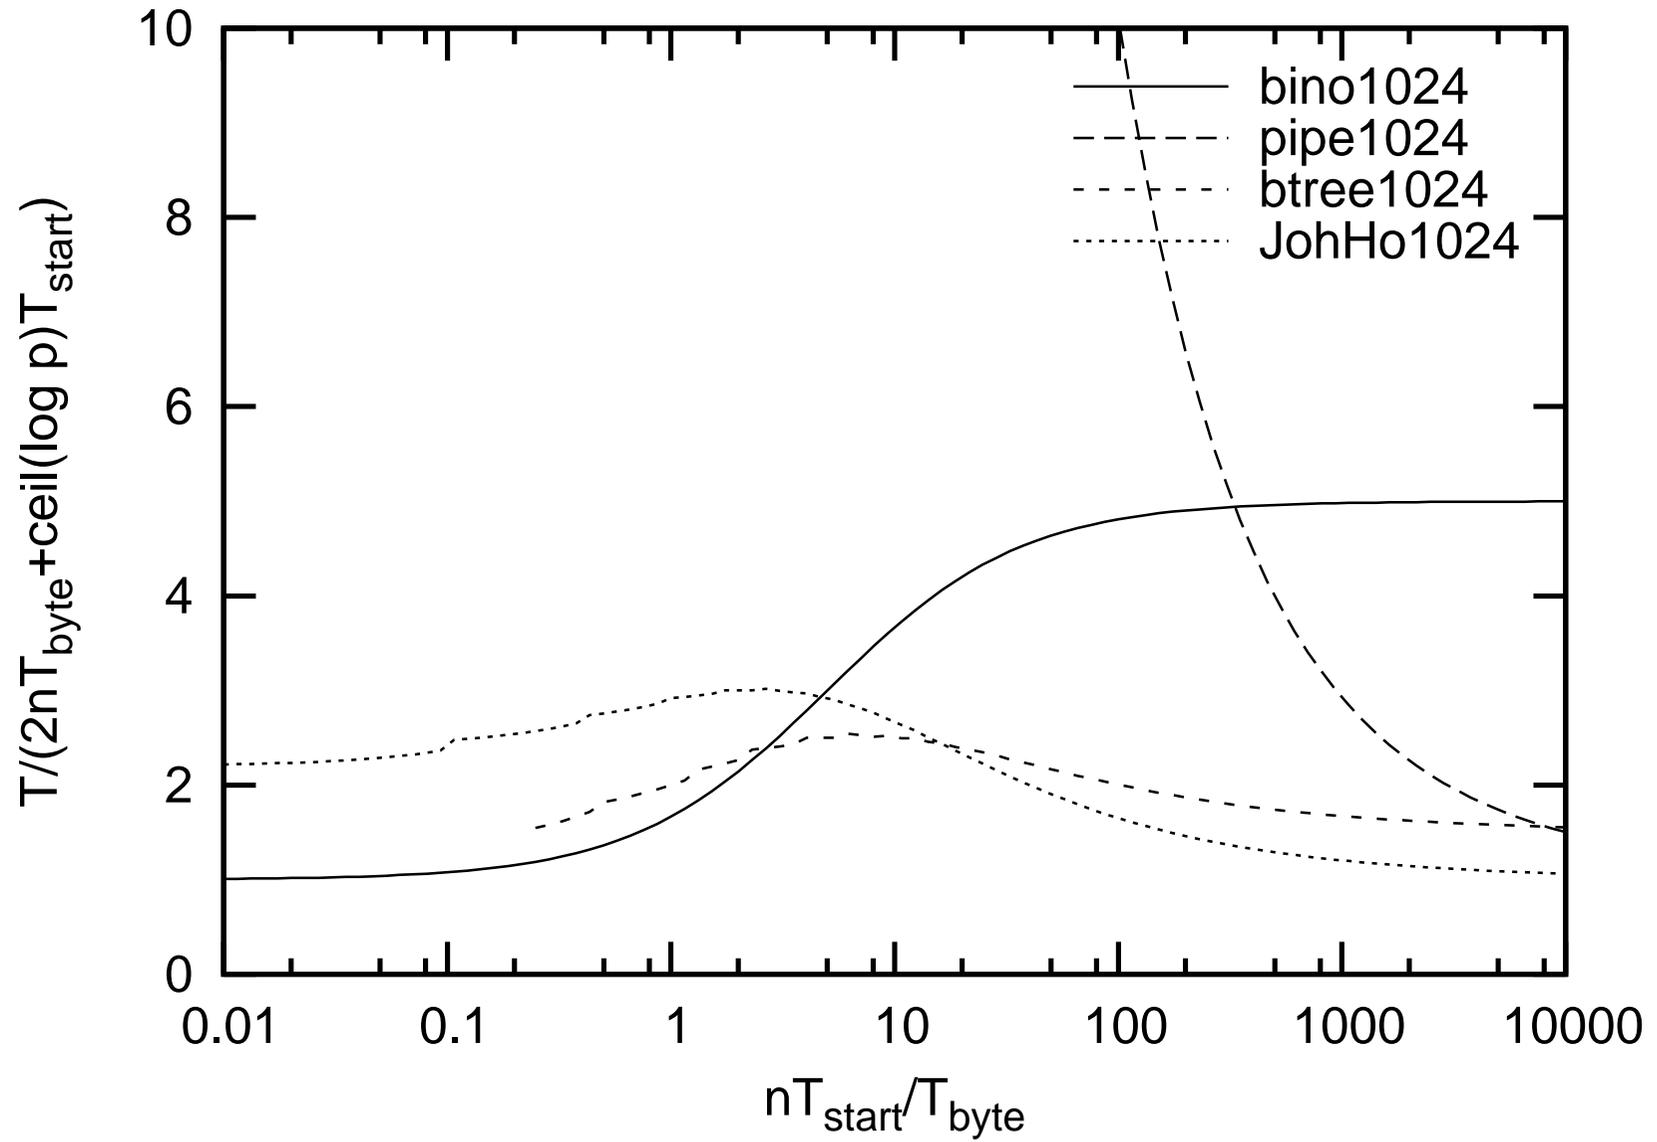
- k Pakete, k teilt n
- k Schritte bis letztes Paket PE 0 verlassen hat
- d Schritte bis es das letzte Blatt erreicht hat
- Insgesamt $d + k$ Schritte

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

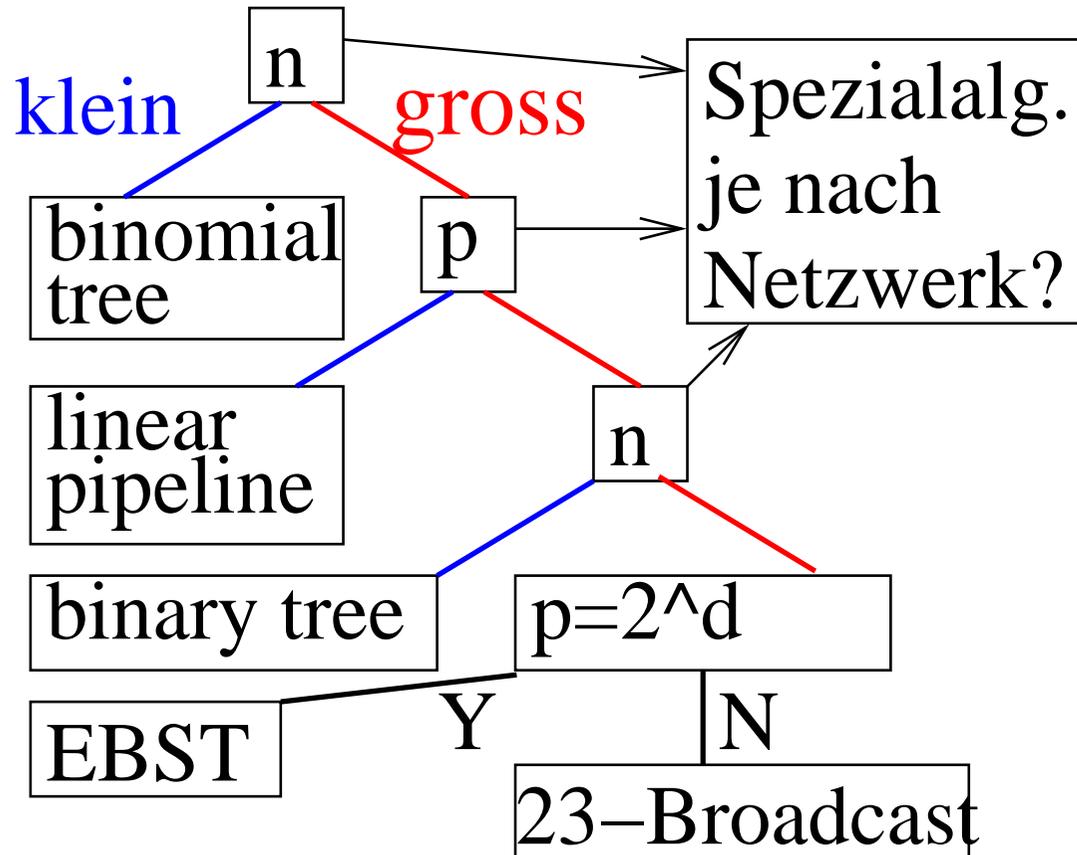
optimales k : $\sqrt{\frac{ndT_{\text{byte}}}{T_{\text{start}}}}$

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





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
- Hyperwürfel werden langsam wenn Kommunikationslatenzen eine große **Varianz haben**
- 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

- 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

- n Eingabewerte. Anfangs n/p pro PE
- u.U. allgemeiner
- Ausgabe global sortiert

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

, ...,

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

$\Downarrow \pi$

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

$\leq \dots \leq$

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

- Vergleichsbasiertes Modell
- $T_{\text{seq}} = T_{\text{compr}} \frac{n}{p} \log \frac{n}{p} + \mathcal{O}\left(\frac{n}{p}\right)$

Vorsicht: abweichende Notation im Skript $n \leftrightarrow n/p$

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

// merge

reduce-by-rows(ranks)

Time

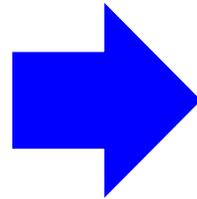
$$\mathcal{O} \left(T_{\text{start}} \log p + T_{\text{byte}} \frac{n}{\sqrt{p}} + \frac{n}{p} \log \frac{n}{p} \right) . \quad (1)$$

Beispiel

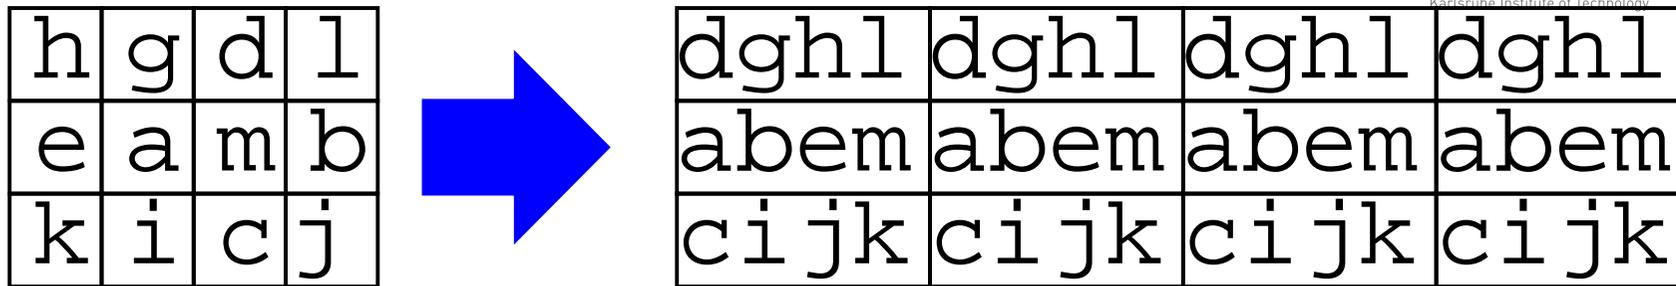
h	g	d	l
e	a	m	b
k	i	c	j

row all-gather-merge

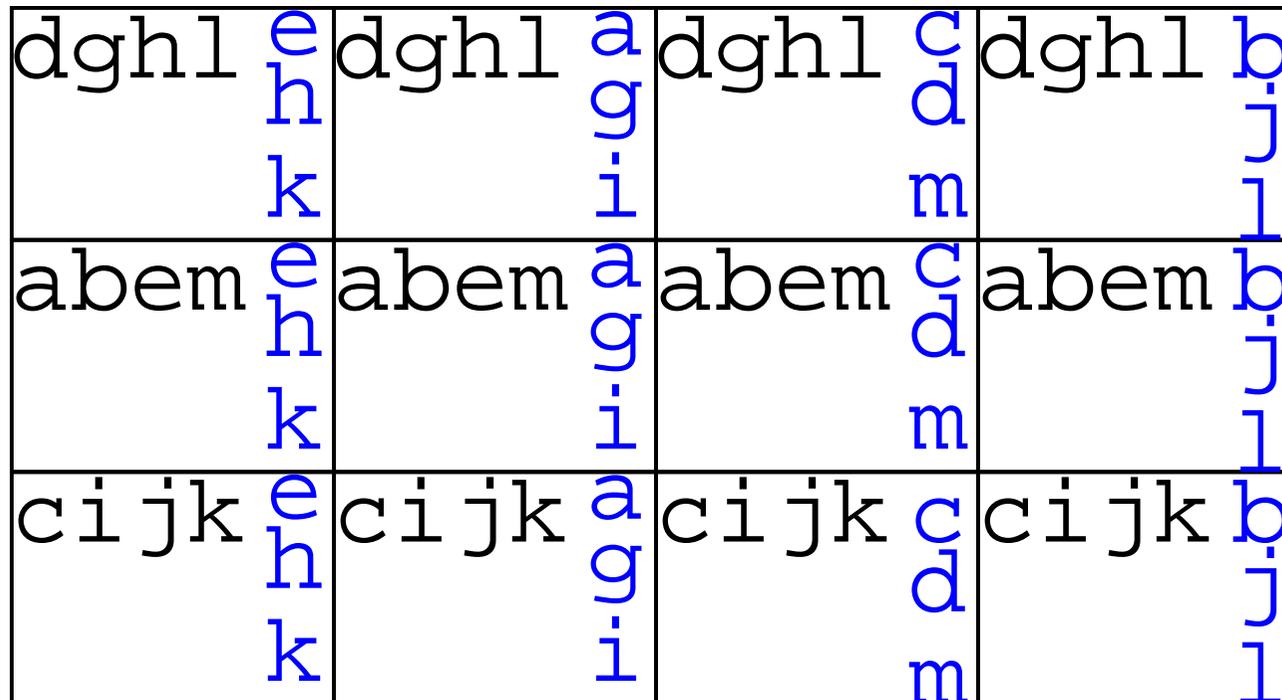
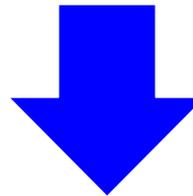
h	g	d	l
e	a	m	b
k	i	c	j



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



row all-gather-merge
 col all-gather-merge



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

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

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

dghl $\begin{matrix} e \\ h \\ k \end{matrix}$ 0123	dghl $\begin{matrix} a \\ g \\ i \end{matrix}$ 1223	dghl $\begin{matrix} c \\ a \\ m \end{matrix}$ 2222	dghl $\begin{matrix} b \\ j \\ i \end{matrix}$ 1113
abem $\begin{matrix} e \\ h \\ k \end{matrix}$ 0013	abem $\begin{matrix} a \\ g \\ i \end{matrix}$ 1113	abem $\begin{matrix} c \\ a \\ m \end{matrix}$ 0023	abem $\begin{matrix} b \\ j \\ i \end{matrix}$ 0113
cij $\begin{matrix} e \\ h \\ k \end{matrix}$ 0223	cij $\begin{matrix} a \\ g \\ i \end{matrix}$ 1333	cij $\begin{matrix} c \\ a \\ m \end{matrix}$ 1222	cij $\begin{matrix} b \\ j \\ i \end{matrix}$ 1122

d g h l
4 6 7 11

a b e m
1 2 5 12

c i j k
3 8 9 10

Genauere Analyse, n 10 byte elemente pro PE

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

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

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

reduce JoHo-Algorithm:

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

Overall:

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

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, $n/p = 32$.

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

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($d[]$, n)

if $n = 1$ **then return**

select a **pivot** v

reorder the elements in d such that

$$d_0 \cdots d_{k-1} \leq v < d_k \cdots d_{n-1}$$

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

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

Anfänger-Parallelisierung

Parallelisierung der rekursiven Aufrufe.

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

- Sehr begrenzter Speedup
- Schlecht für distributed Memory

Theoretiker-Parallelisierung

Zur Vereinfachung: $n = p$.

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. Parallele 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 $p' + i - j$ // $i - j = \sum_{k=0}^i d@k > v$

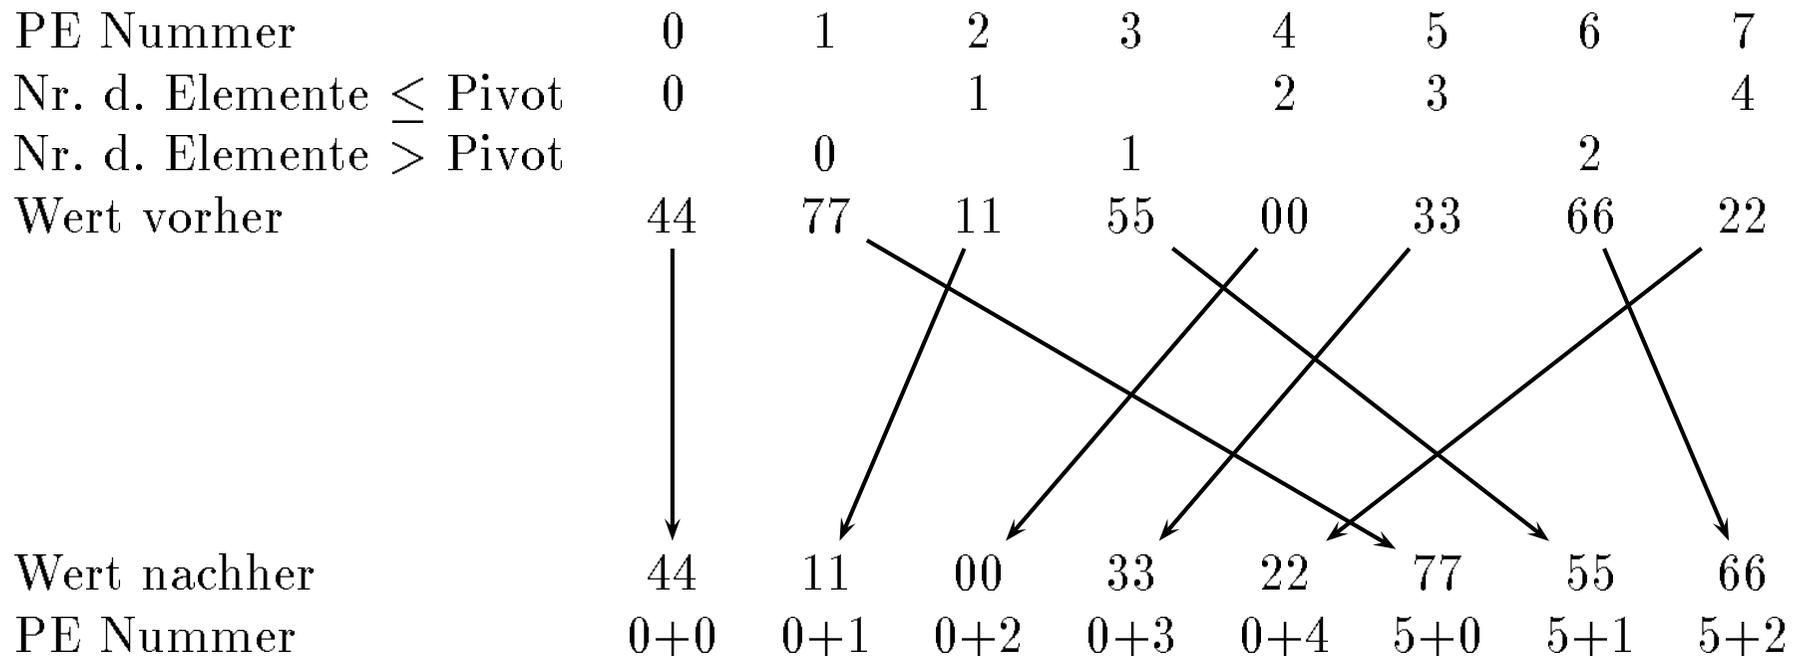
receive d

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

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

Beispiel

pivot $v = 44$



```
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 $\mathcal{O}\left(\frac{n \log n}{p} + \log^2 p\right)$ Algorithmus
- Bei verteiltem Speicher stört, dass jedes Element $\Omega(\log p)$ mal transportiert wird.

$\rightsquigarrow \dots \rightsquigarrow$ Zeit $\mathcal{O}\left(\frac{n}{p}(\log n + T_{\text{byte}} \log p) + T_{\text{start}} \log^2 p\right)$

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

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

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

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

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

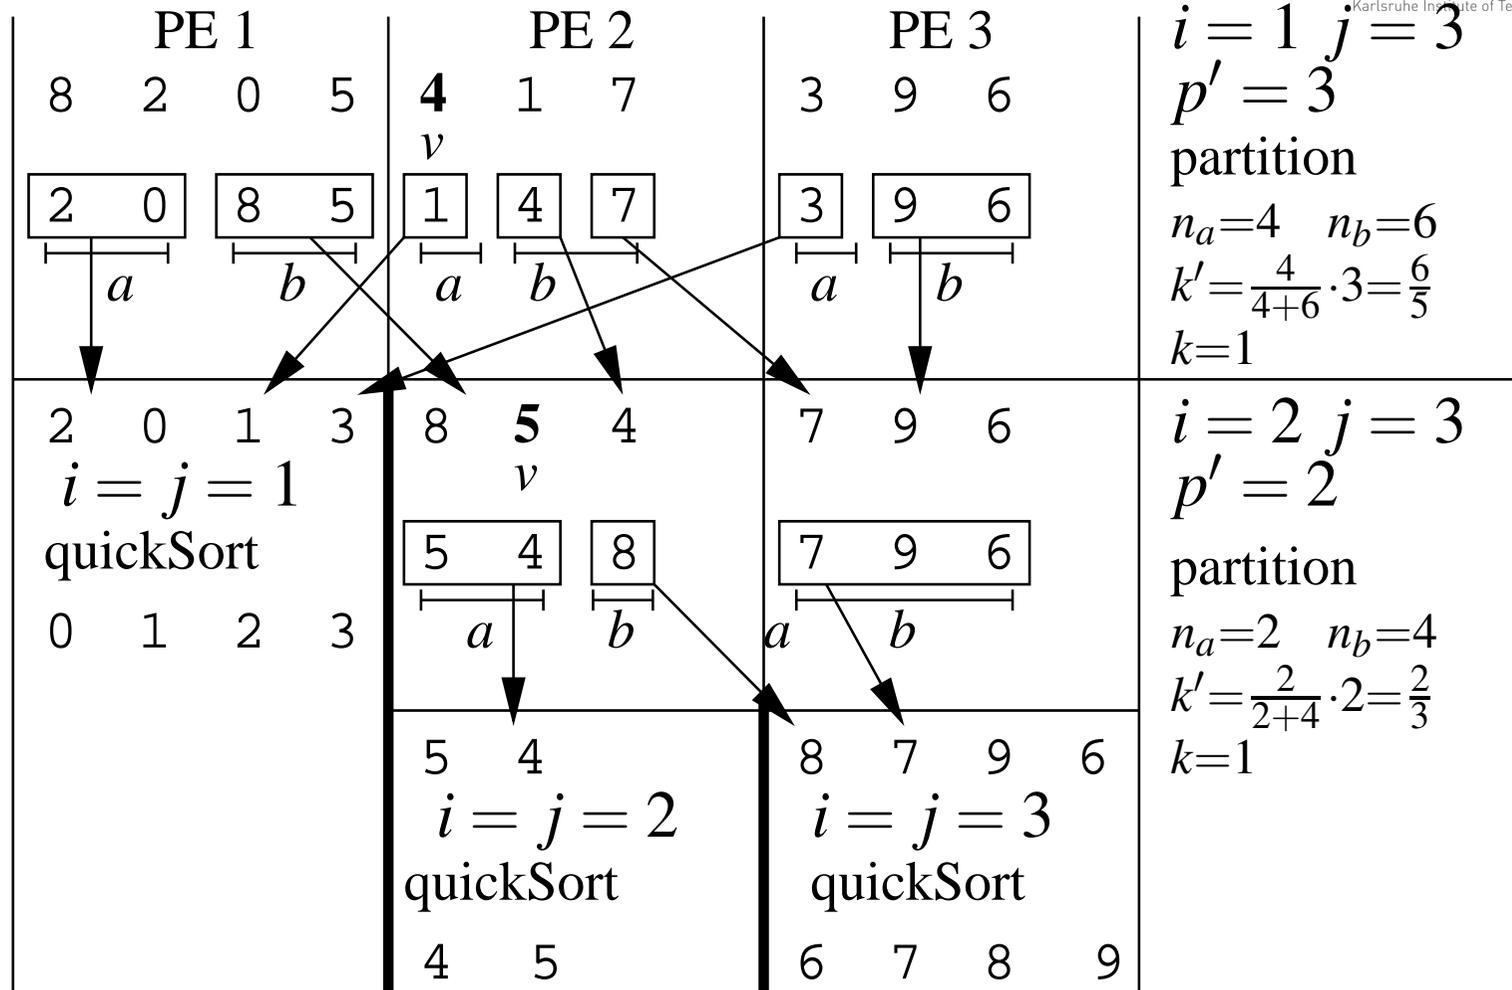
choose $k \in \{\lfloor k' \rfloor, \lceil k' \rceil\}$ such that $\max \left\{ \left\lceil \frac{n_a}{k} \right\rceil, \left\lceil \frac{n_b}{p' - k} \right\rceil \right\}$ is minimized

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

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

Vereinfachtes 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:

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

Bessere Lastbalancierung?

- Janus-quicksort? Axtmann, Wiebigke, Sanders, IPDPS 2018
- bei kleinem p' pivot sorgfältig wählen
- bei kleinem p' ($\Theta(\log p)$) auf sample sort umsteigen?

Alternative: immer Halbierung der Prozessoren, Randomisierung, sorgfältige Pivot-Wahl.

Axtmann, Sanders, ALENEX 2017

Multi-Pivot Verfahren

Vereinfachende Annahme: Splitter fallen vom Himmel

//Für $0 < k < p$ sei v_k das Element mit Rang $k \cdot n / p$

//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

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

Idealisierende Annahme ist realistisch für **Permutation**.

Sample Sort

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

sort $[s_1, \dots, s_{S p}]$ // or only

for $i := 1$ to $p - 1$ do $v_i := s_{S i}$ // multiple selection

$v_0 := -\infty$; $v_p := \infty$

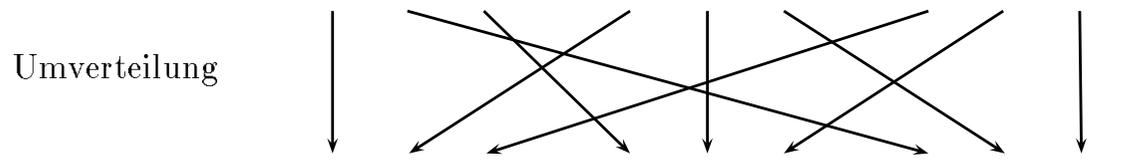
unsortierte Eingangsdaten	19 7 12 1 9 13 25 4 2	6 30 17 13 10 11 16 27 22	3 20 14 18 5 16 15 21 8
------------------------------	-----------------------------	---------------------------------	-------------------------------

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	I_0	I_1	I_2	I_0	I_1	I_2
	1	12	25	6	17	30	3	14	20
	4	13	19	10	13	27	5	18	21
	2				11	22	8	16	
	7				16			15	
9									



lokal sortierte Daten	I_0			I_1			I_2		
	1	2	3	11	12	13	19	20	21
	4	5	6	13	14	15	22	25	27
	7	8	9	16	16	18	30		
	10								

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

Lemma:

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

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

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

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

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

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

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

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

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

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:

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

$$\Leftrightarrow S \geq \frac{4}{\varepsilon^2} \ln n$$



Analyse von Sample Sort

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

klein wenn $n \gg p^2 \log p$

Samples Sortieren

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

Samples Sortieren

effizient falls $n \gg$

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

$$\frac{p^2 \log p T_{\text{compr}}}{\varepsilon^2}$$

$$\frac{p^2 T_{\text{byte}}}{\varepsilon^2 T_{\text{compr}}}$$

$$\frac{p^2 T_{\text{byte}}}{\log p T_{\text{compr}}}$$

$$\frac{p^2 T_{\text{byte}}}{\log p T_{\text{compr}}}$$

MPI Sample Sort – Init and Local Sample

Many thanks to Michael Axtmann

```
template<class Element> 1
void parallelSort(MPI_Comm comm, vector<Element>& data, 2
                  MPI_Datatype mpiType, int p, int myRank) 3
{ random_device rd; 4
  mt19937 rndEngine(rd()); 5
  uniform_int_distribution<size_t> dataGen(0, data.size() - 1); 6
  vector<Element> locS; // local sample of elements from input <data> 7
  const int a = (int)(16*log(p)/log(2.)); // oversampling ratio 8
  for (size_t i=0; i < (size_t)(a+1); ++i) 9
    locS.push_back(data[dataGen(rndEngine)]); 10
```

Find Splitters

```
vector<Element> s(locS.size() * p); // global samples 1
```

```
MPI_Allgather(locS.data(), locS.size(), mpiType, 2
```

```
    s.data(), locS.size(), mpiType, comm); 3
```

```
sort(s.begin(), s.end()); // sort global sample 5
```

```
for (size_t i=0; i < p-1; ++i) s[i] = s[(a+1) * (i+1)]; //select splitters 6
```

```
s.resize(p-1); 7
```

Partition Locally

```
vector<vector<Element>> buckets(p); // partition data           1
for(auto& bucket : buckets) bucket.reserve((data.size() / p) * 2); 2
for( auto& el : data) {                                           3
    const auto bound = upper_bound(s.begin(), s.end(), el);      4
    buckets[bound - s.begin()].push_back(el);                    5
}                                                                    6
data.clear();                                                     7
```

Find Message Sizes

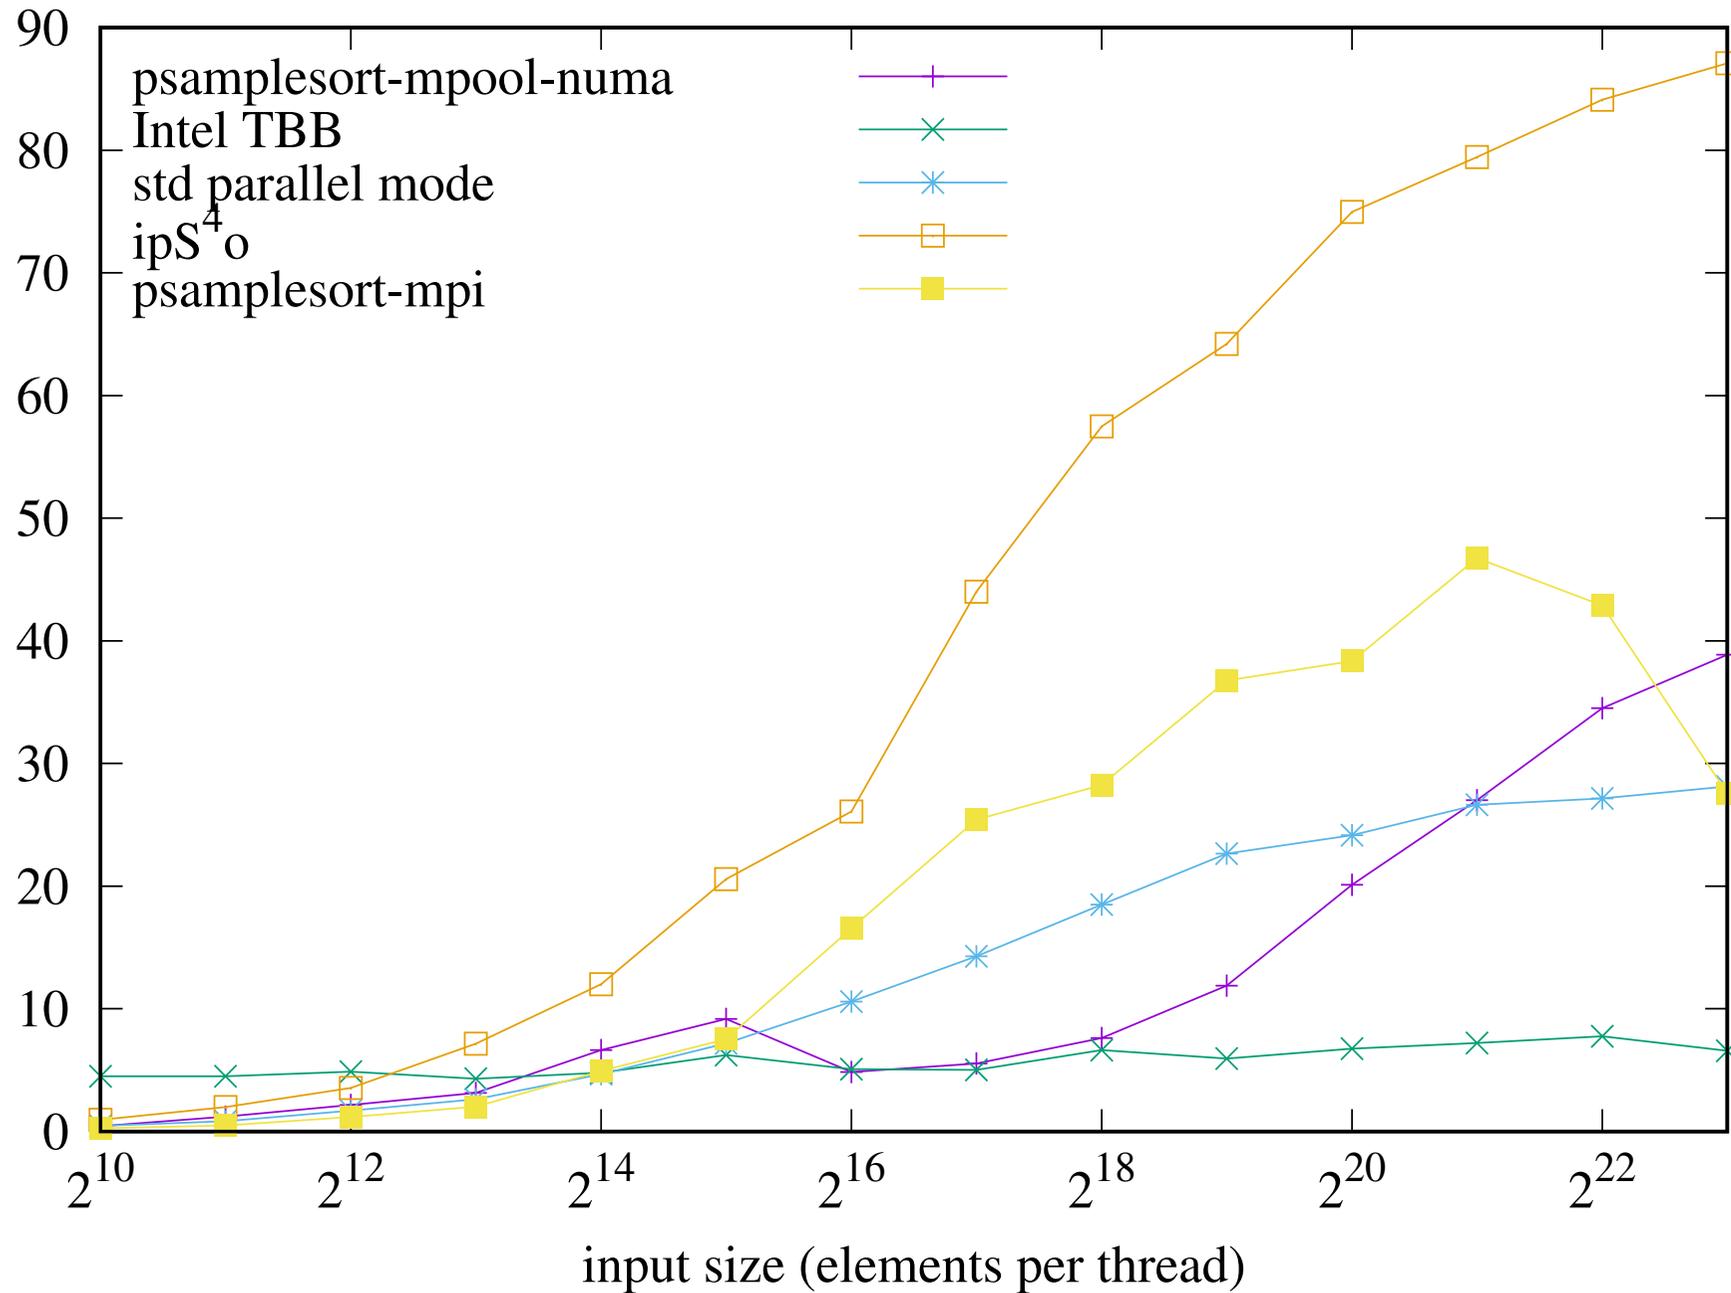
```
// exchange bucket sizes and calculate send/recv information      1
vector<int> sCounts, sDispls, rCounts(p), rDispls(p + 1);        2
sDispls.push_back(0);                                           3
for (auto& bucket : buckets) {                                   4
    data.insert(data.end(), bucket.begin(), bucket.end());      5
    sCounts.push_back(bucket.size());                             6
    sDispls.push_back(bucket.size() + sDispls.back());           7
}                                                                  8
MPI_Alltoall(sCounts.data(),1,MPI_INT,rCounts.data(),1,MPI_INT,comm); 9
// exclusive prefix sum of recv displacements                  10
rDispls[0] = 0;                                                 11
for(int i = 1; i <= p; i++) rDispls[i] = rCounts[i-1]+rDispls[i-1]; 12
```

Data Exchange and Local Sorting

```
vector<Element> rData(rDispls.back()); // data exchange      1
MPI_Alltoallv(data.data(), sCounts.data(), sDispls.data(), mpiType,      2
              rData.data(), rCounts.data(), rDispls.data(), mpiType, comm);      3

sort(rData.begin(), rData.end());      5
rData.swap(data);      6
}      7
```

Experiments Speedup on 4× Intel E7-8890 v3



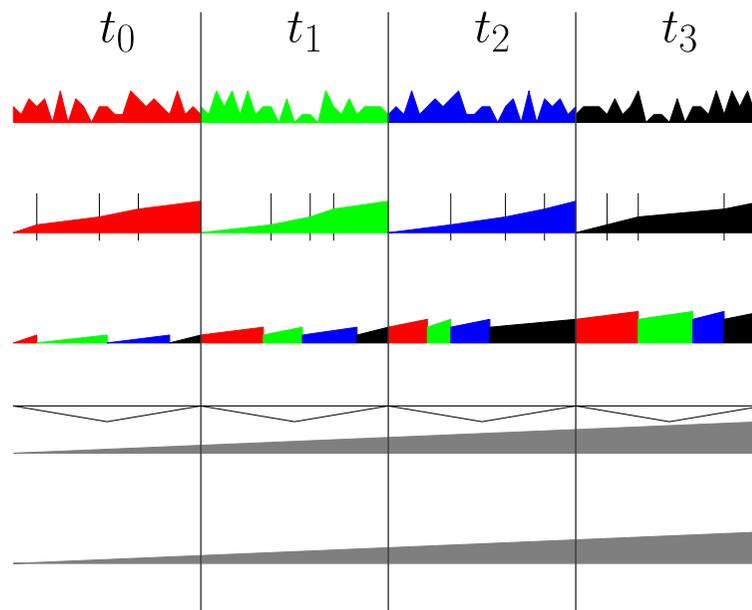
Sortieren durch Mehrwegemischen

Function mmSort(d, n, p) // shared memory not SPMD

PE i sorts $d[in/p..(i+1)n/p]$; barrier synchronization

PE i finds v_i with rank in/p in d ; barrier synchronization

PE i merges p subsequences with $v_k \leq d_j < v_{k+1}$



Multisequence Selection

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

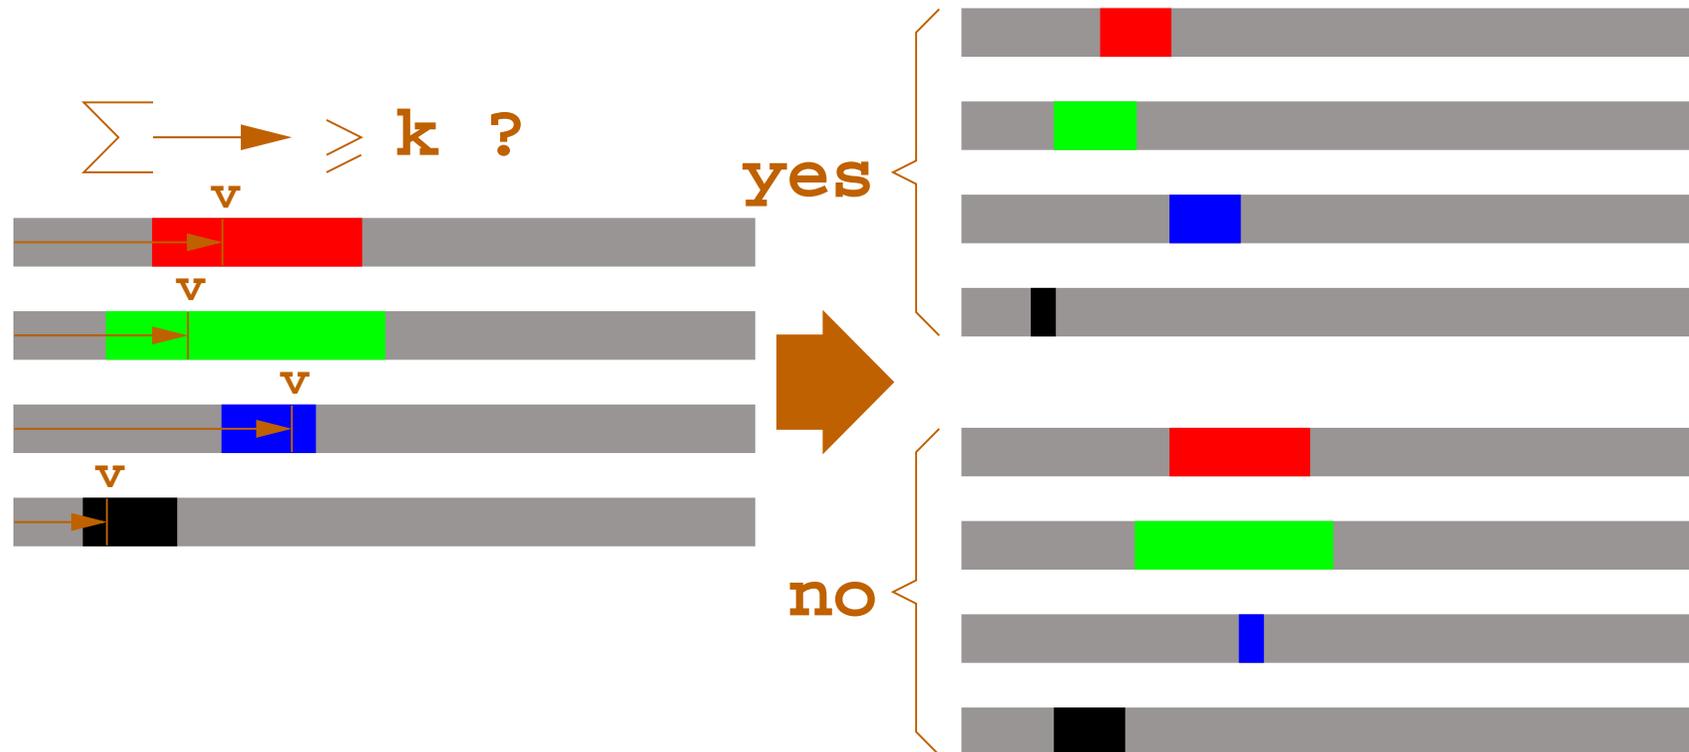
Vergleichsbasierte **untere Schranke**: $\mathcal{O}\left(p \log \frac{n}{p}\right)$

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

Splitter Selection

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

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



Idee:

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

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

Analyse von p -way Mergesort

$$T_{p\text{MergeSort}}(p, n) = \mathcal{O} \left(\underbrace{\frac{n}{p} \log \frac{n}{p}}_{\text{lokal sortieren}} + \underbrace{p \log n \log \frac{n}{p}}_{\text{ms-selection}} + \underbrace{\frac{n}{p} \log p}_{\text{merging}} \right)$$

- effizient falls $n \gg p^2 \log p$
- deterministisch (fast)
- perfekte Lastbalancierung
- etwas schlechtere konstante Faktoren als sample sort

Verteilte Multisequence Selection

Owner computes Paradigma

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

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

überall $p - 1$ lokale Suchen.

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

Erwartete Zeit

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

Verteilte Multisequence Selection

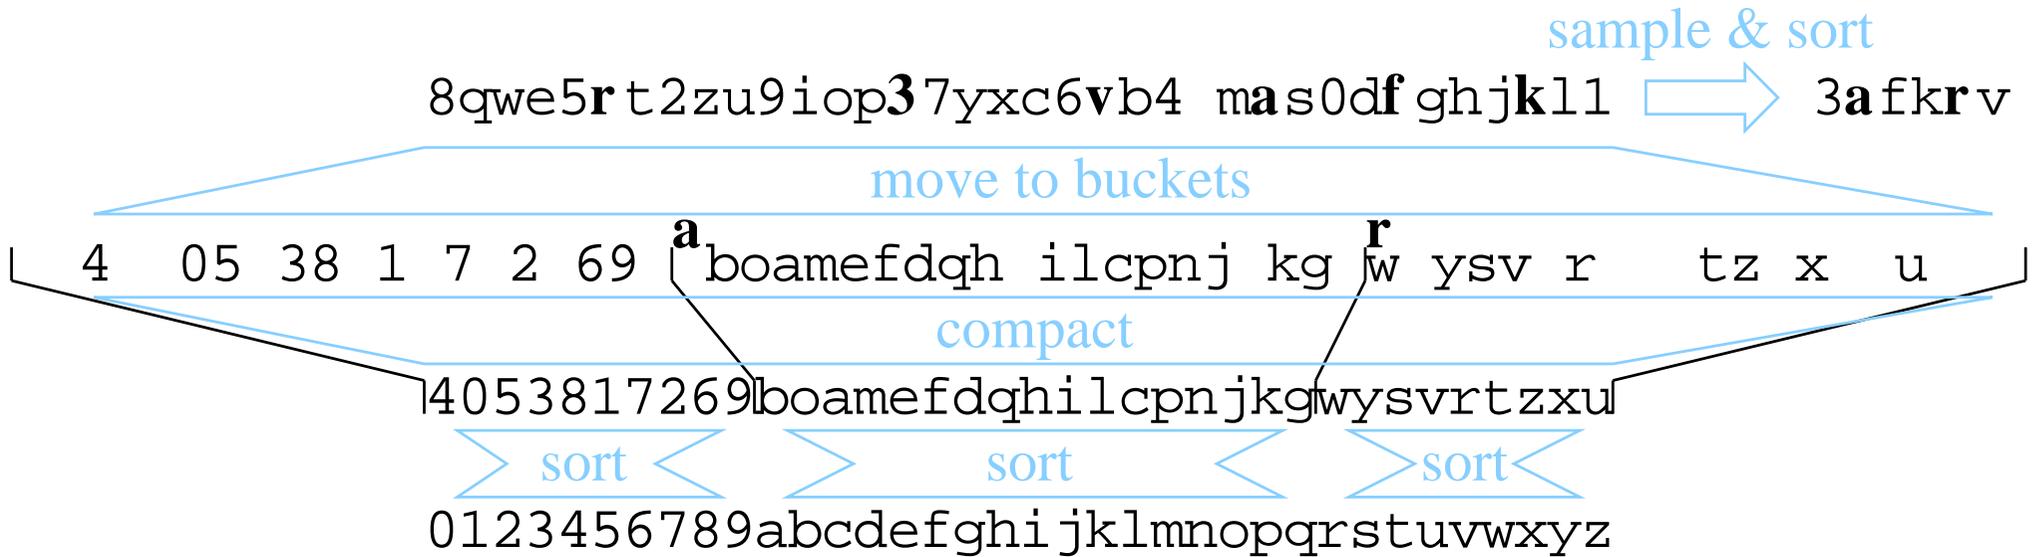
Function dmSelect(s : Seq of Elem; k : Array[1.. p] of \mathbb{N}) : Array[1.. p] of \mathbb{N}
 ℓ, r, m, v, σ : Array [1.. p] of \mathbb{N}
for $i := 1$ **to** p **do** $(\ell_i, r_i) := (0, |s|)$ // initial search ranges
while $\exists i, j : \ell_i @ j \neq r_i @ j$ **do** // or-reduction
 $v := \text{pickPivotVector}(s, \ell, r)$ // reduction, prefix sum, broadcast
 for $i := 1$ **to** p **do** $m_i := \text{binarySearch}(v_i, s[\ell_i..r_i])$
 $\sigma := \sum_i m @ i$ // vector valued reduction
 for $i := 1$ **to** p **do** **if** $\sigma_i \geq k_i$ **then** $r_i := m_i$ **else** $\ell_i := m_i$
return ℓ

CRCW Sortieren in logarithmischer Zeit

Sei $n = p$.

- 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 zufällige freie Position in ihrem Bucket
- Kompaktiere mittels Präfixsummen
- Rekursion

Beispiel



Mehr zu Sortieren I

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

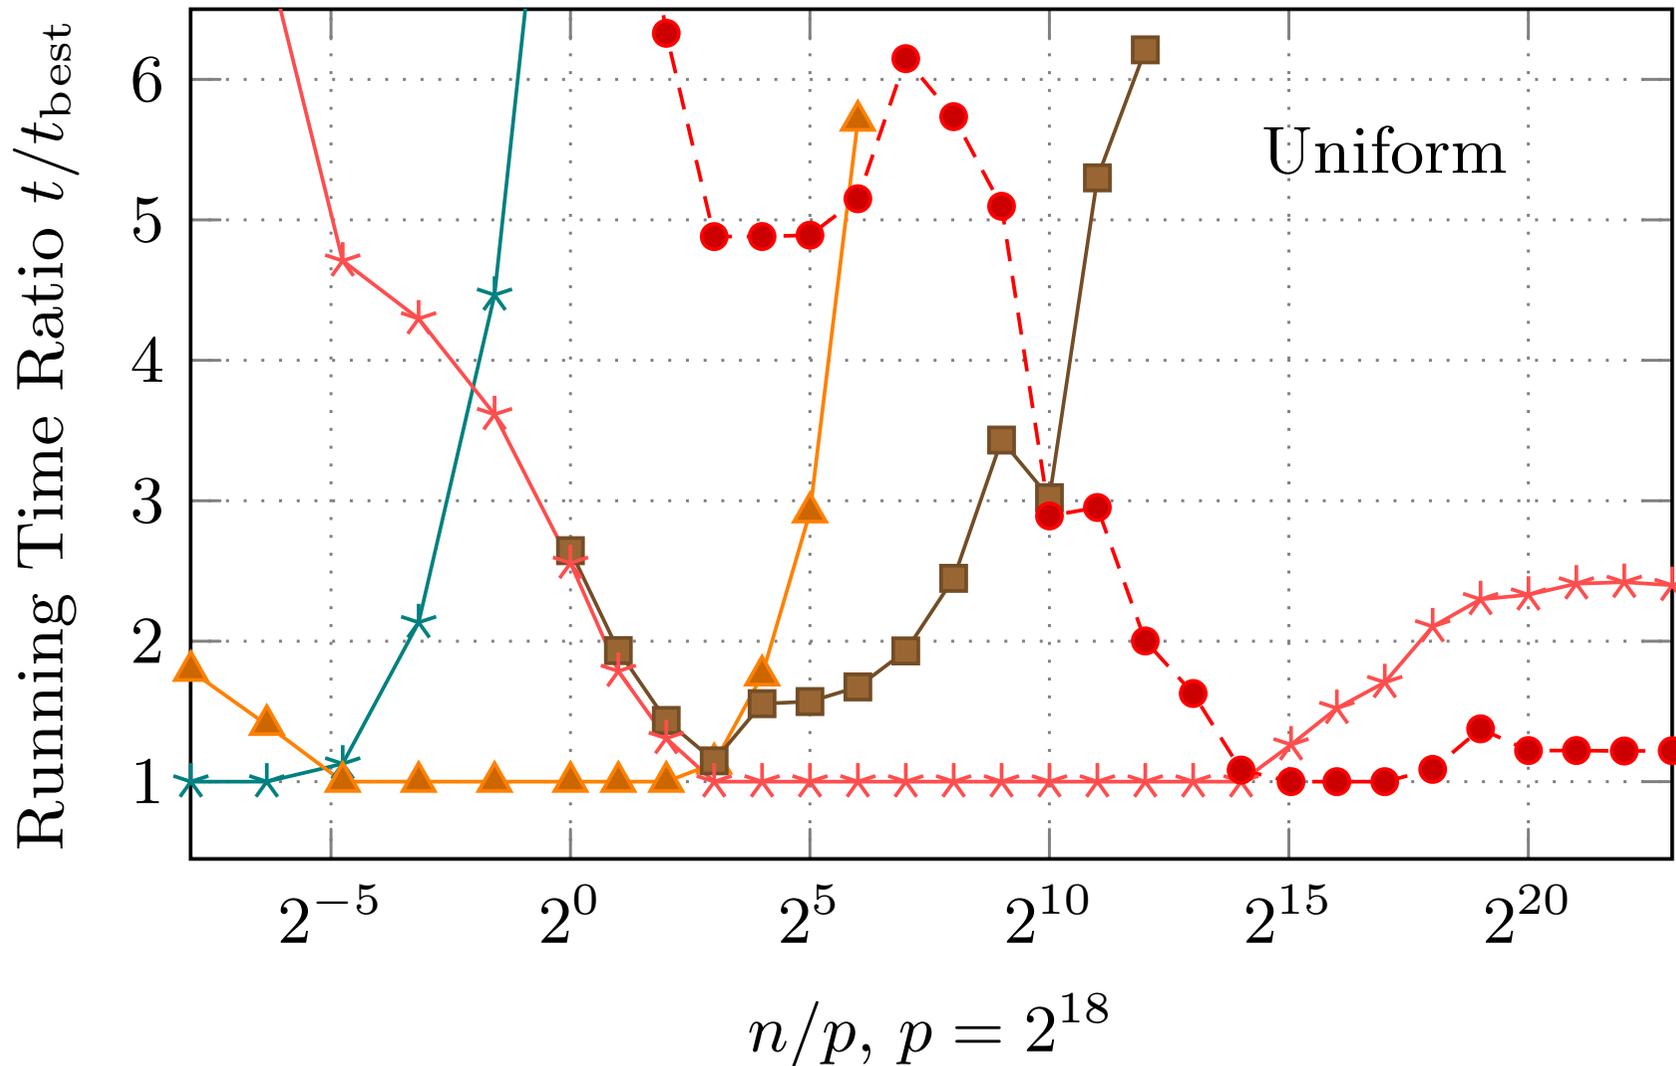
Mehr zu Sortieren II

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

Mehr-Phasen-Sample/Merge-Sort: allgemeinerer Kompromiss zwischen Latenz und Kommunikationsvolumen, z.B. AMS-Sort
Axtmann, Bingmann, Schulz, Sanders SPAA 2015

Slowdown wrt Fastest Algorithm

- *— GatherM —▲— RFIS —■— Bitonic
- *— RQuick -●- RAMS



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, Batchersort, 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

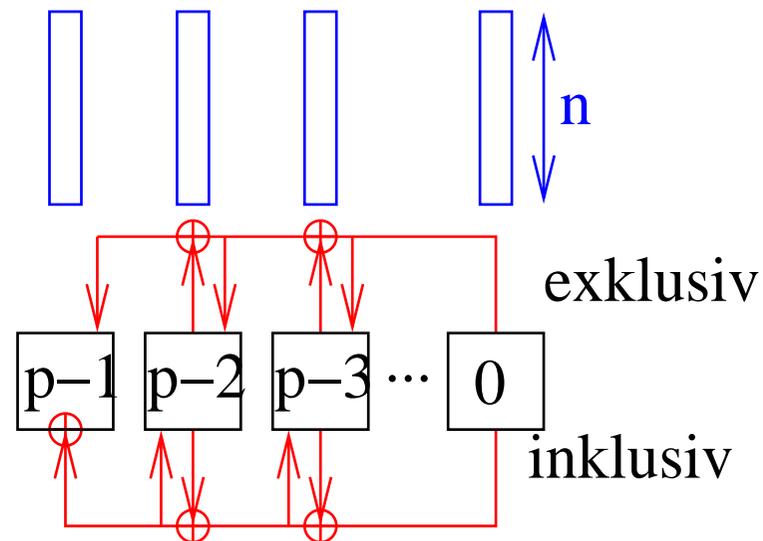
- Broadcast
- Reduktion
- Präfixsummen
- nicht hier: Sammeln / Austeilen (Gather / Scatter)
- Gossiping (= All-Gather = Gather + Broadcast)
- All-to-all Personalized Communication
 - gleiche Nachrichtenlängen
 - ungleiche Nachrichtenlängen, = *h*-Relation

Präfixsummen

[Leighton 1.2.2] Gesucht

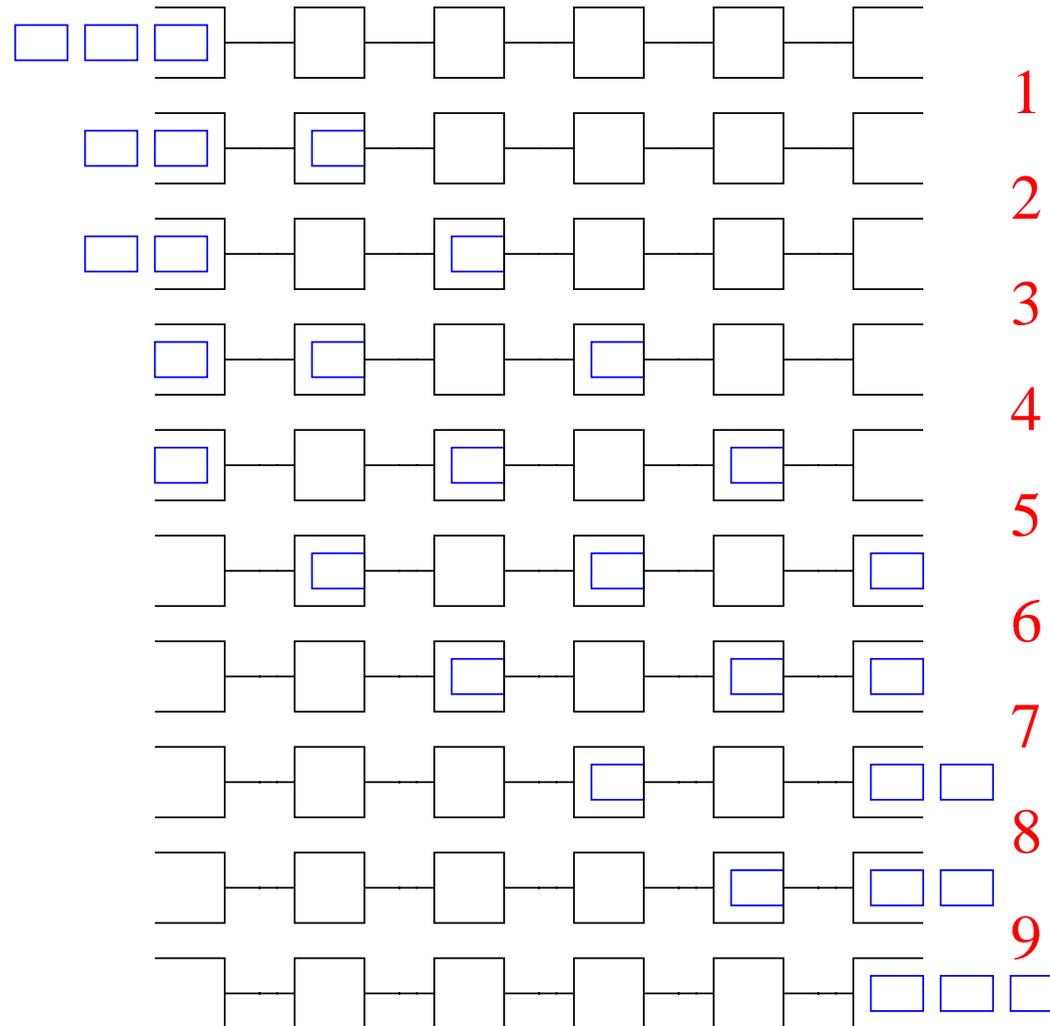
$$x@i := \bigotimes_{i' \leq i} m@i'$$

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

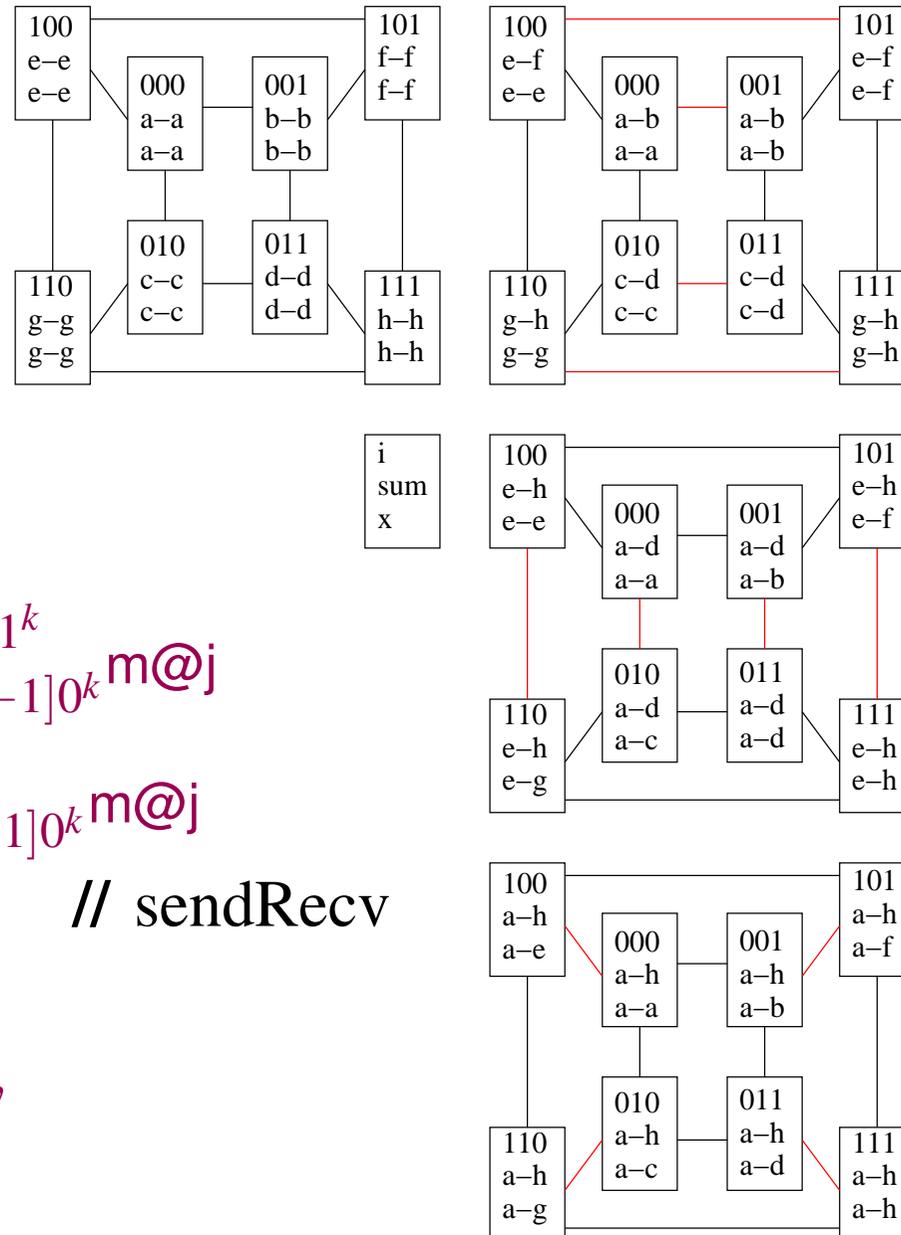
invariant $x = \bigotimes_{j=i[k..d-1]}^i 0^k m @ j$

$y := \sigma @ (i \oplus 2^k)$ // 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 $\sum_{j=i'}^i x@j$

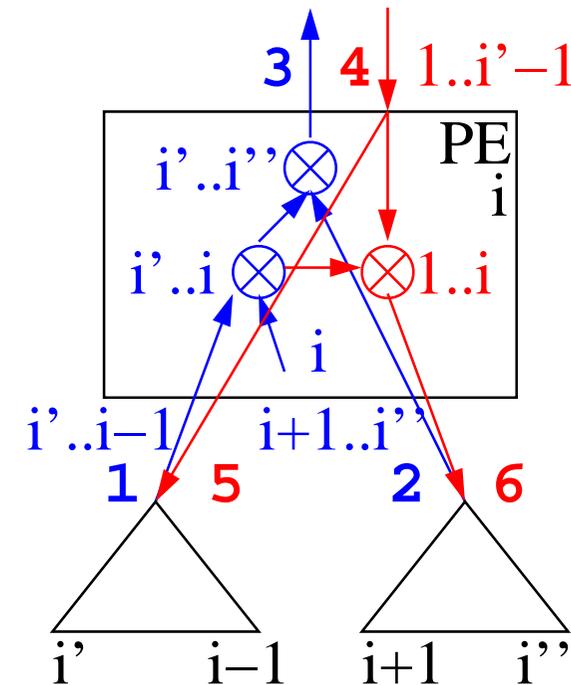
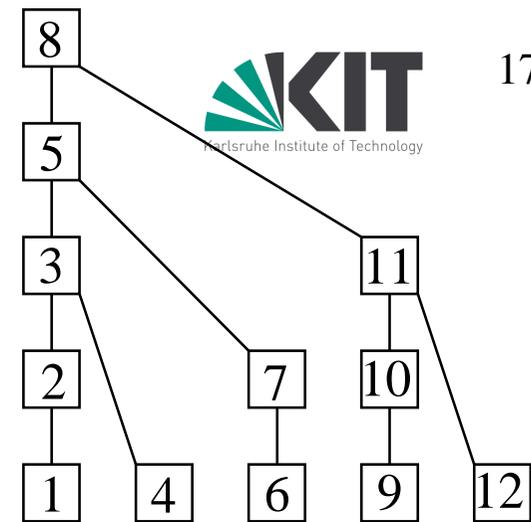
Abwärtsphase: PE i empfängt $\sum_{j=1}^{i'-1} x@j$

(Wurzel: = 0 !)

und reicht das nach links weiter.

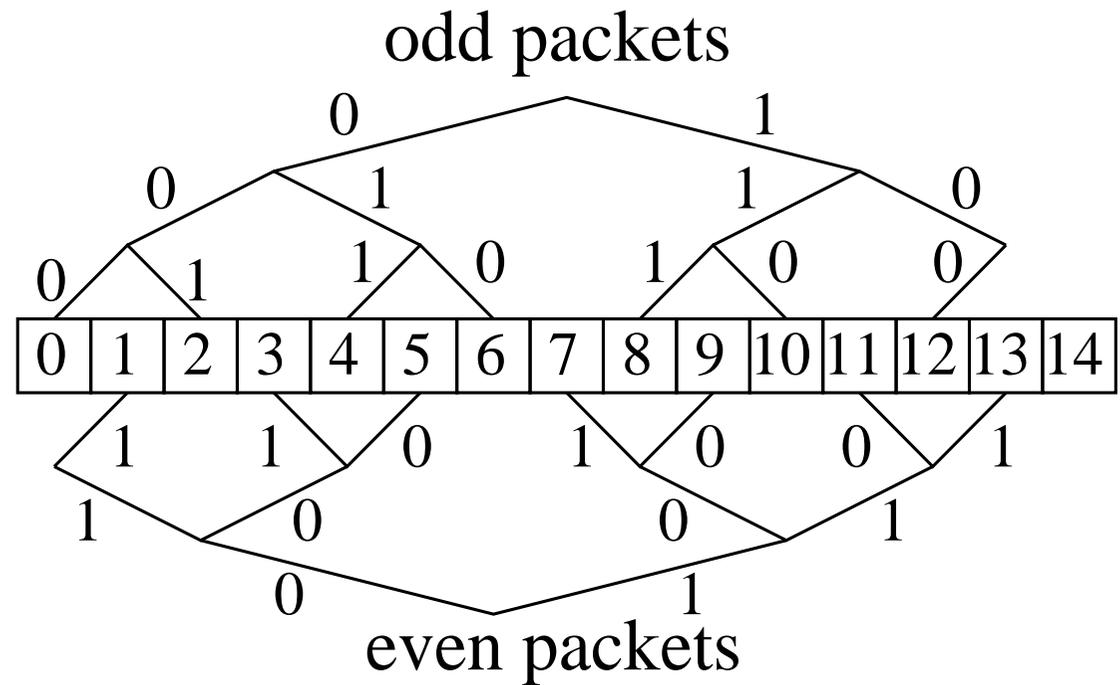
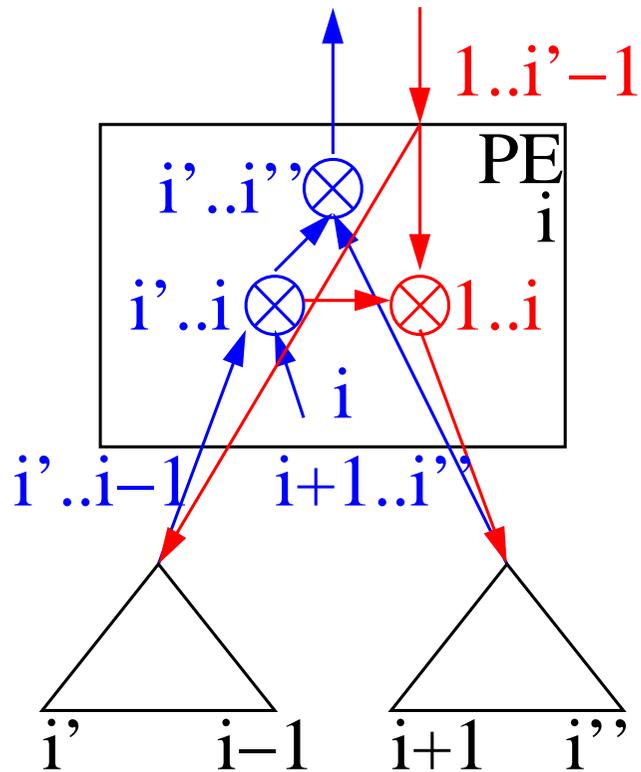
rechter Teilbaum kriegt $\sum_{j=1}^i x@j$

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:

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

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**

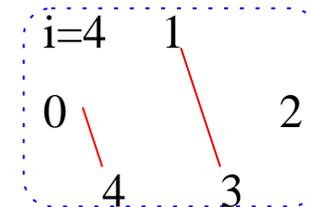
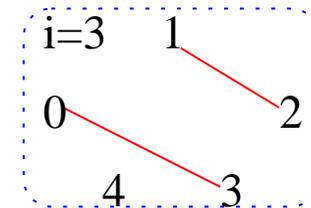
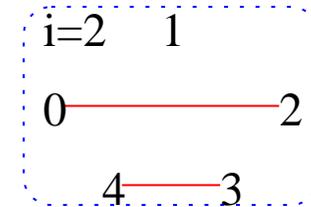
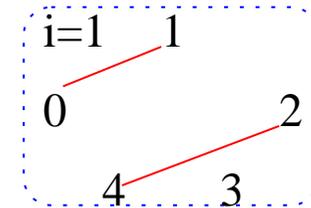
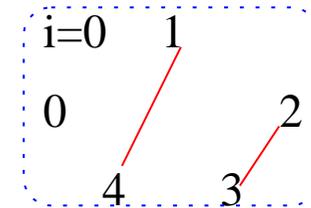
 Exchange data with PE $(i - j) \bmod p$

Paarweise Kommunikation (Telefonmodell):

Der Partner des Partners von j in Runde i ist

$$i - (i - j) \equiv j \pmod{p}$$

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

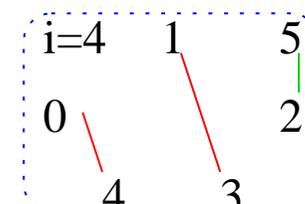
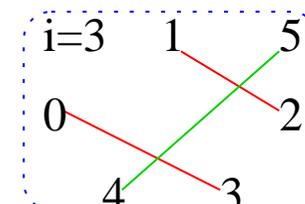
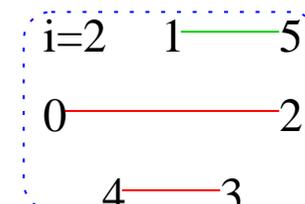
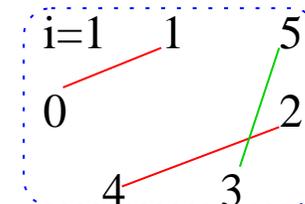
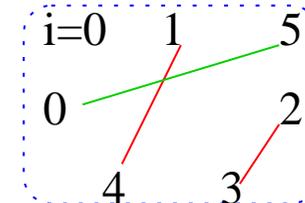
if $j = \text{idle}$ **then**

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 $n \rightarrow \infty$



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.,

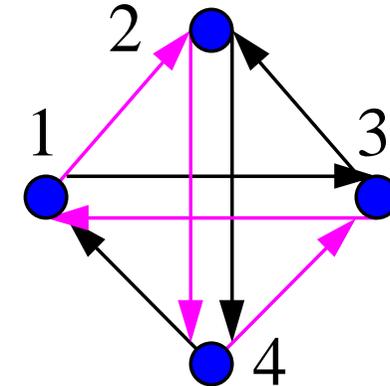
keine zwei gleichfarbigen Kanten

inzident zu einem Knoten.

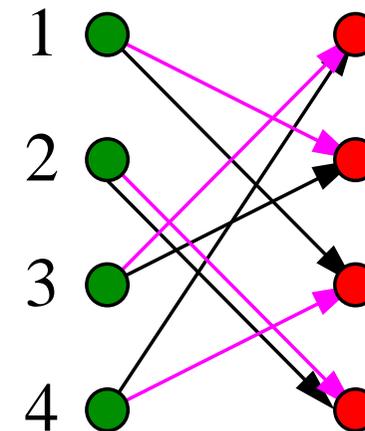
for $j := 1$ **to** h **do**

Sende Nachrichten der Farbe j

optimal wenn man paketweise Auslieferung postuliert



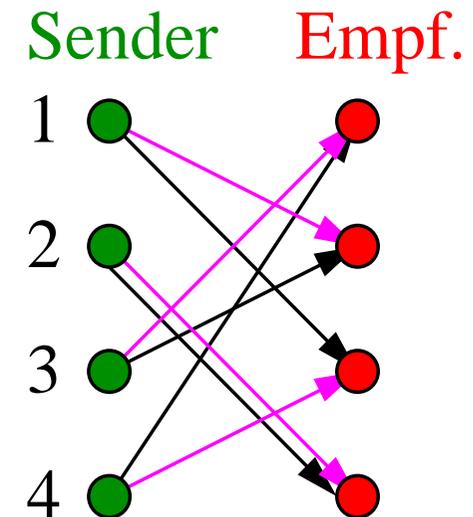
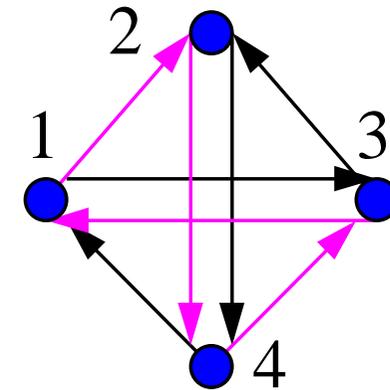
Sender Empf.



Offline h -Relationen im duplex Modell

Probleme:

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



Offline h -Relationen im Simplex-Modell

[Petersen 1891? Shannon 1949?]

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

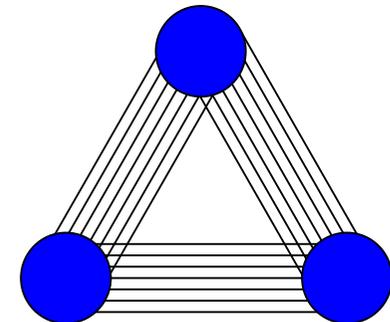
mit $|\{\{i, j\} \in E\}| = \#$ Pakete zwischen PE i und PE j (beide Richtungen).

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

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

 Sende Nachrichten der Farbe j

optimal?? ?



How Helper Hasten h -Relations

[Sanders Solis-Oba 2000]

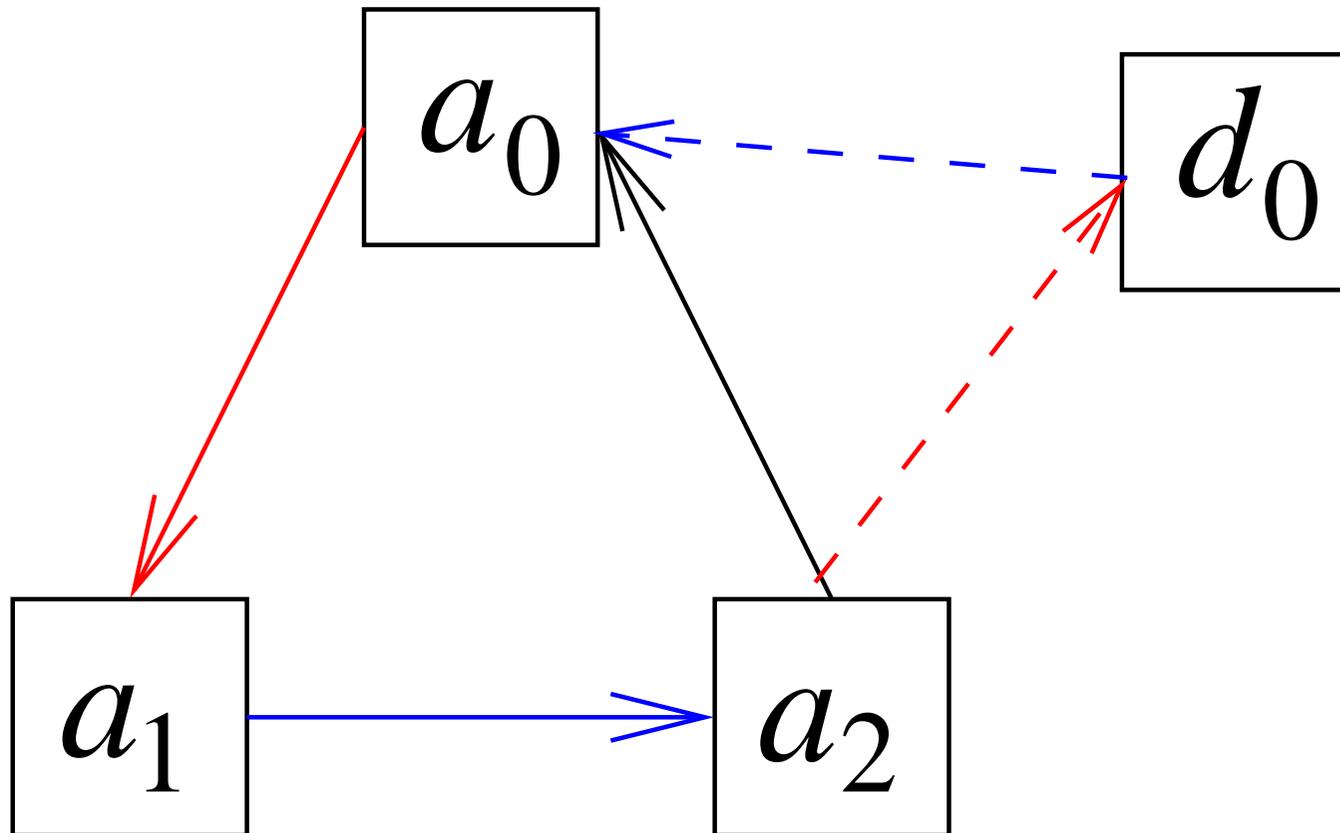
Satz 4. Für h -Relationen im Simplexmodell gilt

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

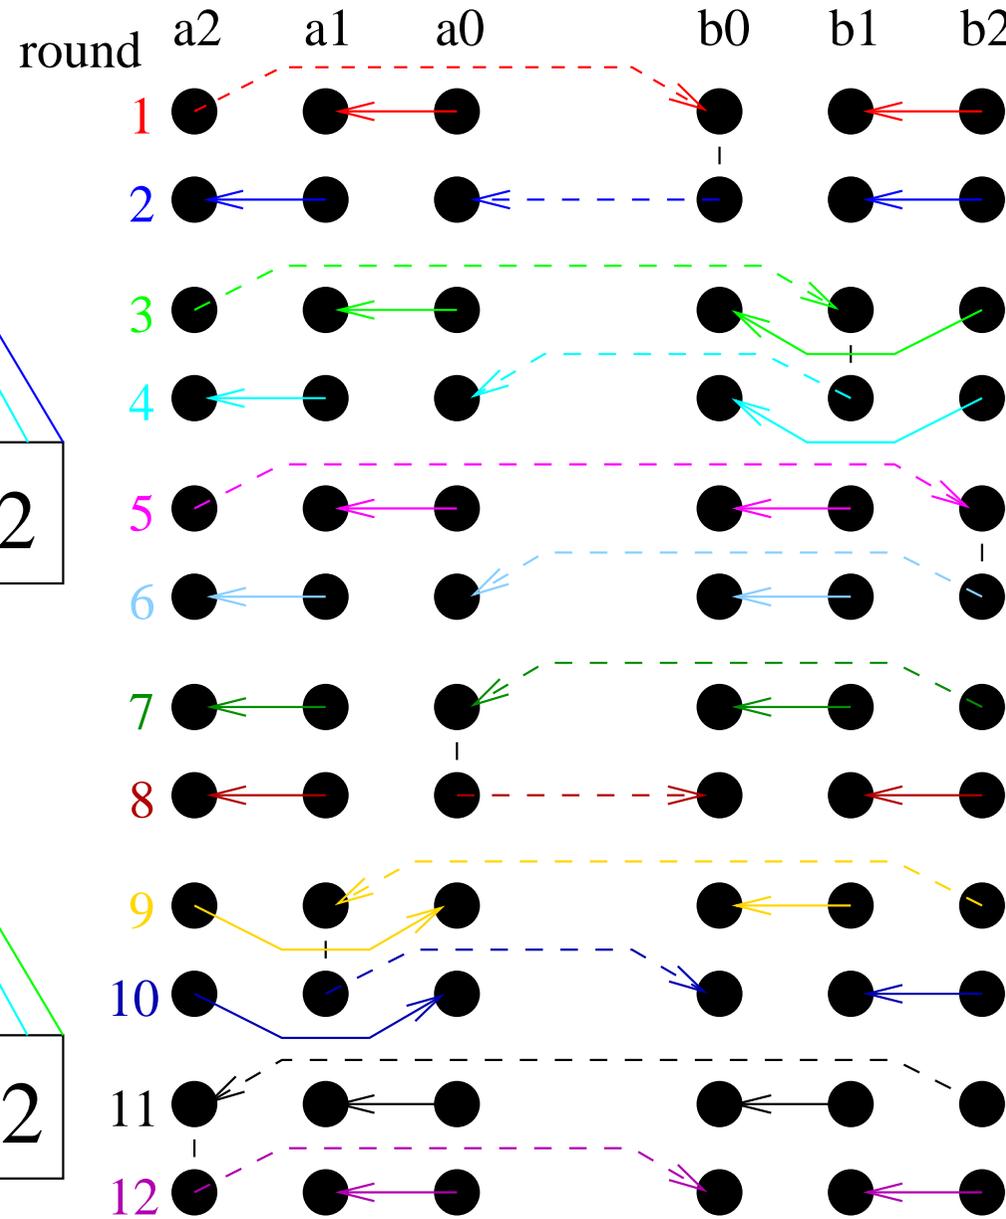
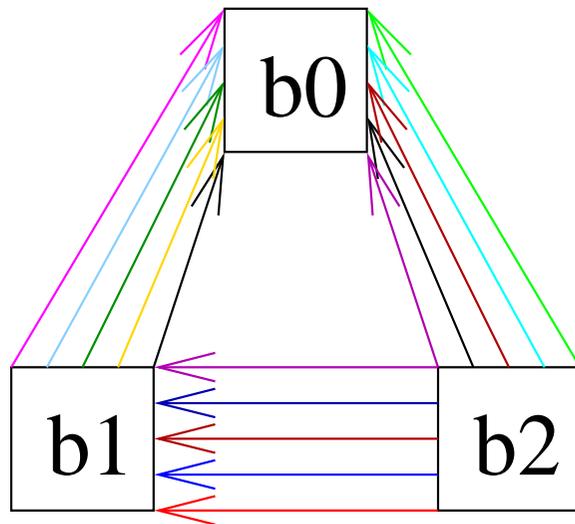
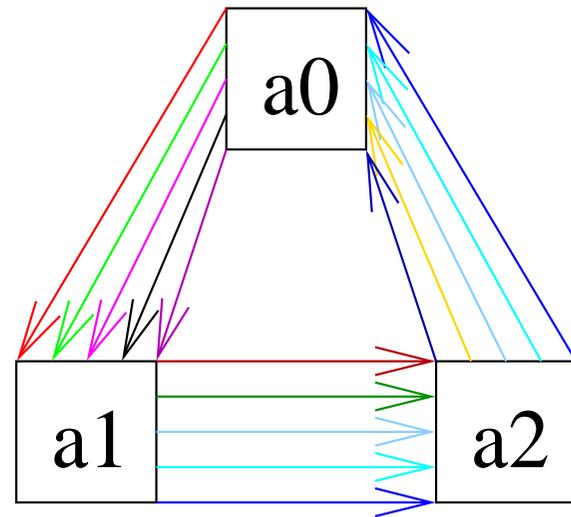
Andererseits gibt es eine *untere Schranke*

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

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
- Farbklasse in bipartitem Graph \rightsquigarrow kantendisjunkte einfache Kreise im Ursprungsgraphen (2-Relationen)
- Ursprüngliche Kommunikationsrichtung wiederherstellen

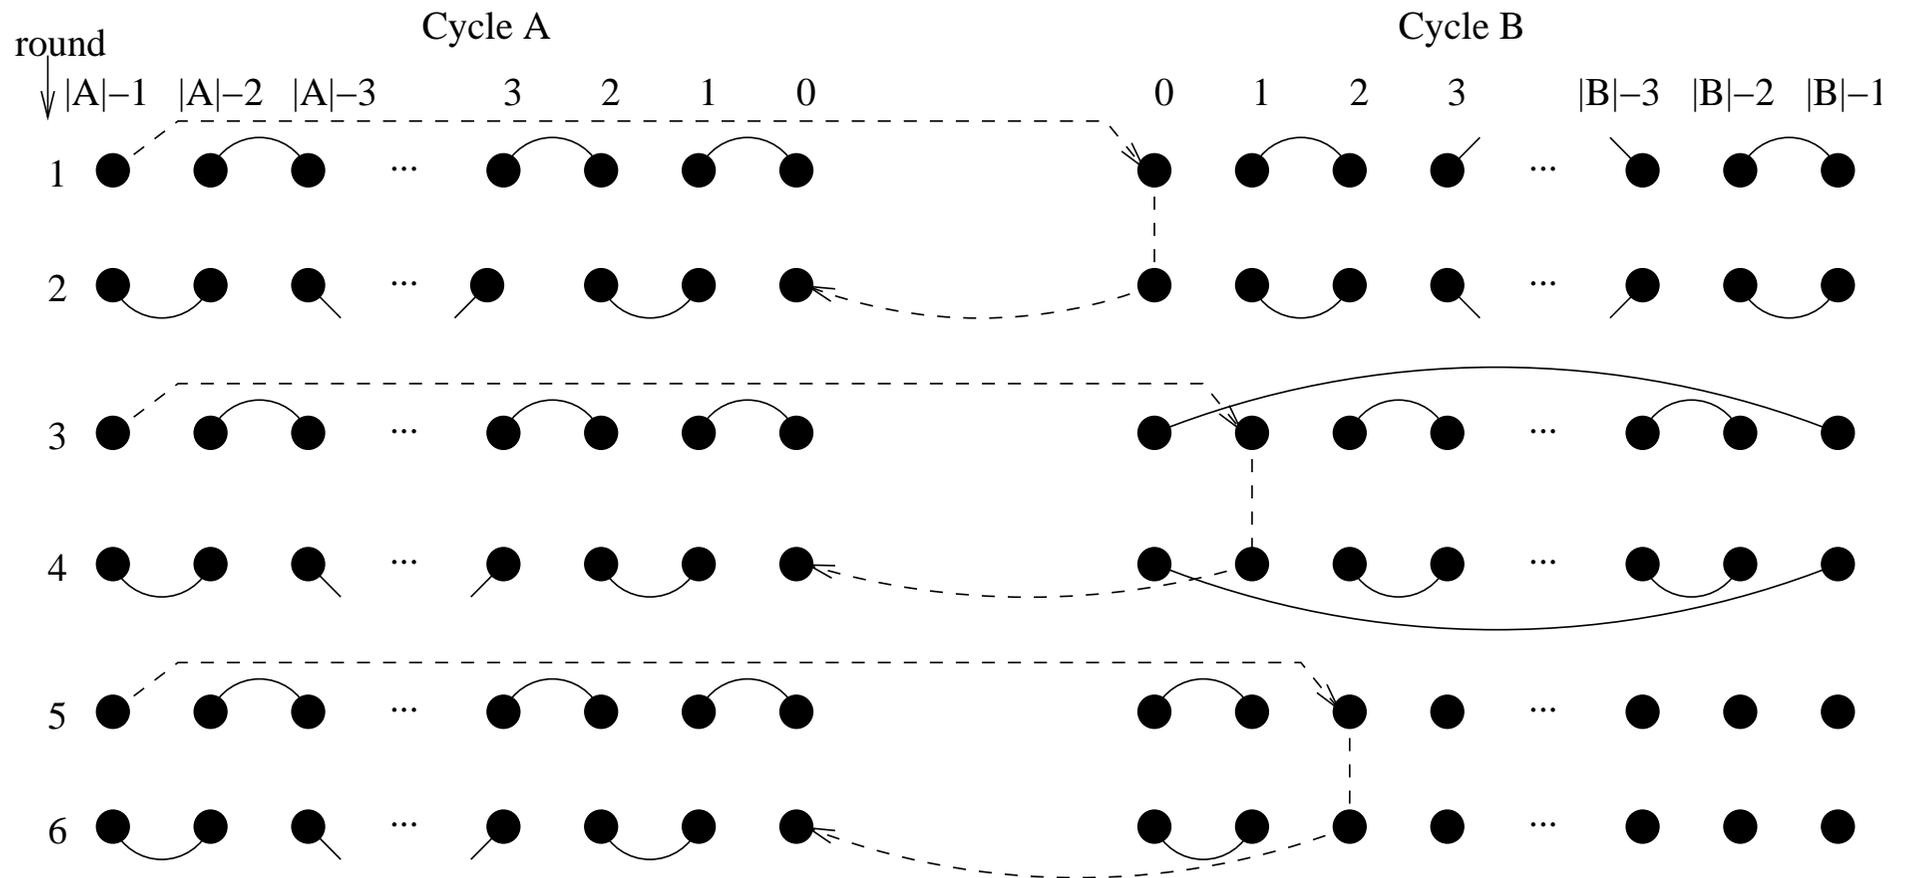
2-Relationen routen für gerade p

Paare ungerade Kreise.

1 Kreise haben nichts zu tun \rightsquigarrow einfachster Fall

Zwei Ungerade Kreise mit ≥ 3 Knoten

Spalte Pakete in 5 Teilpakete



Dann das ganze umdrehen

Ungerade p

Idee: Lösche in jedem 2-Faktor eine Kante.

Tu dies “Immer woanders”

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

\rightsquigarrow 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** $a[i] := a[i] \odot m[j][\left((i-1)\frac{n[j]}{p} + 1..i\frac{n[j]}{p}\right)]$

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

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

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

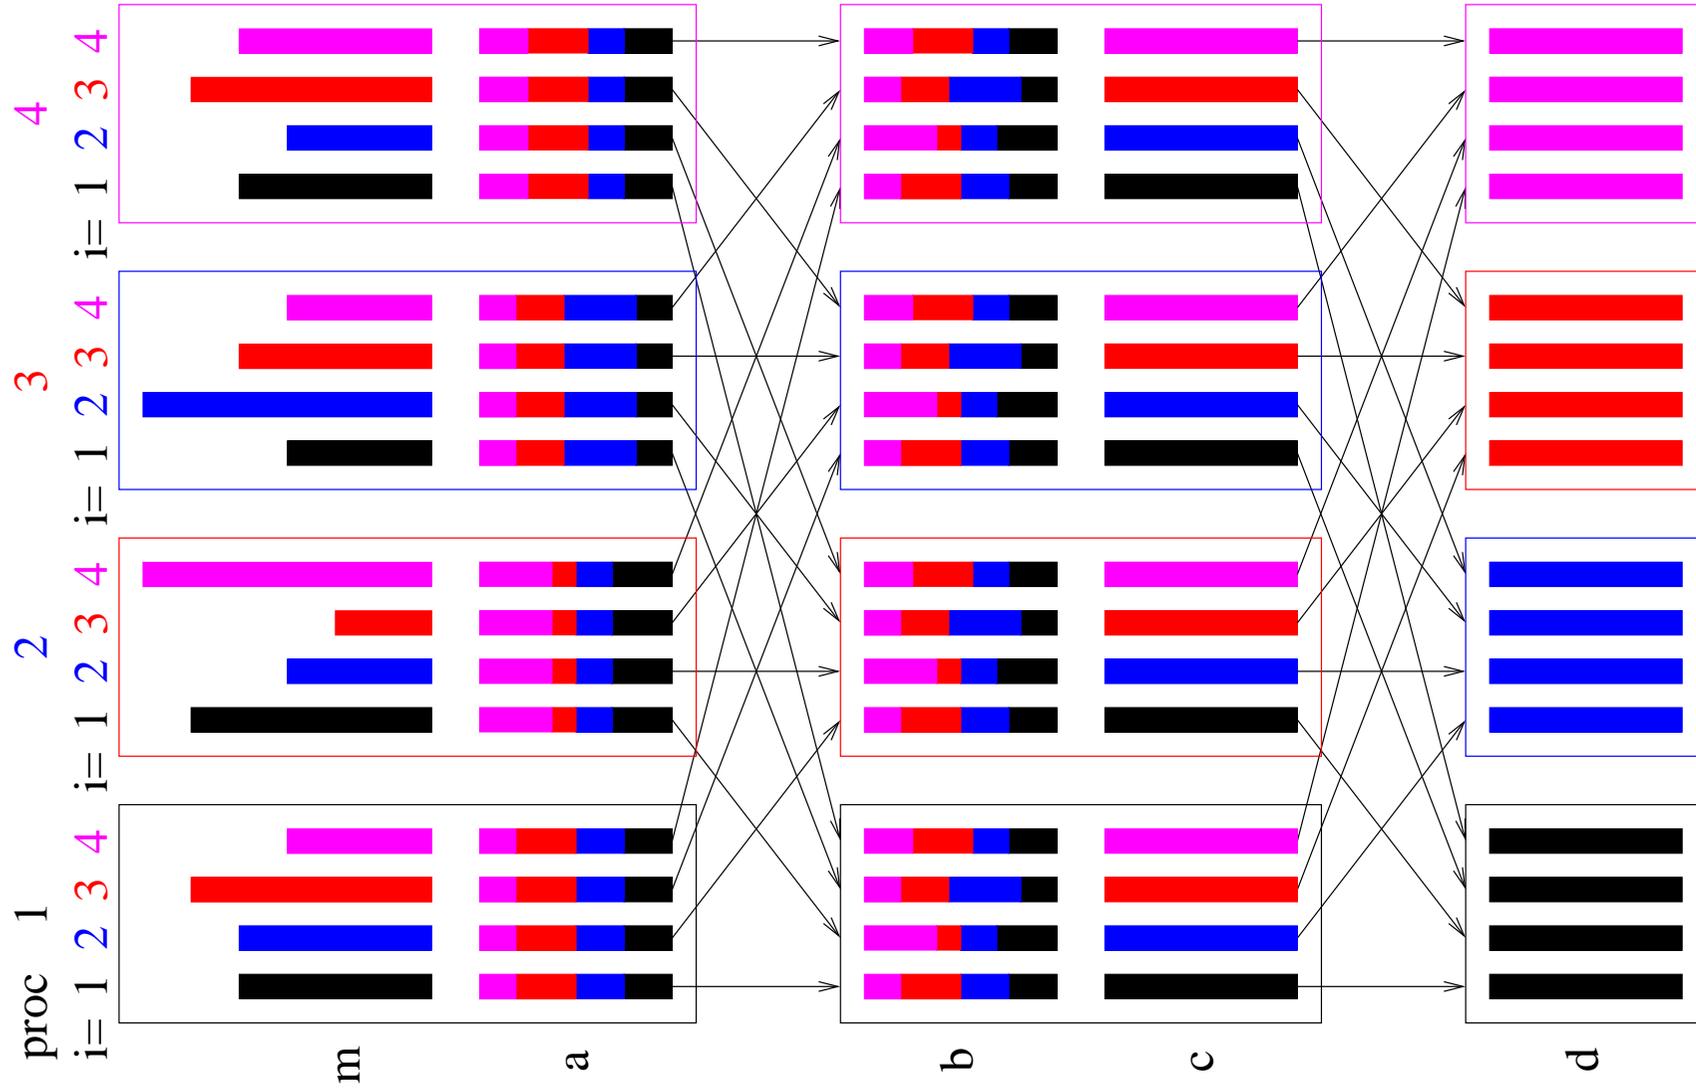
for $j := 1$ **to** p **do**

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

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

$s := s \cup$ “start sending m at time t ”

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

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

Prioritätslistenoperationen und eine p -bit Bitvektoroperation anfällt.

\rightsquigarrow 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 Approximationsalgorithmen?
- Parallele 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?

Parallele Prioritätslisten

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

Binary Heaps (sequentiell)

Procedure insert(e) $M := M \cup \{e\}$ // $\mathcal{O}(\log n)$

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_{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

$Q = \{\text{root node}\}$: 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

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

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 \rightarrow die maximale Pfadlänge von einem Knoten in Q zur optimalen Lösung wird reduziert.

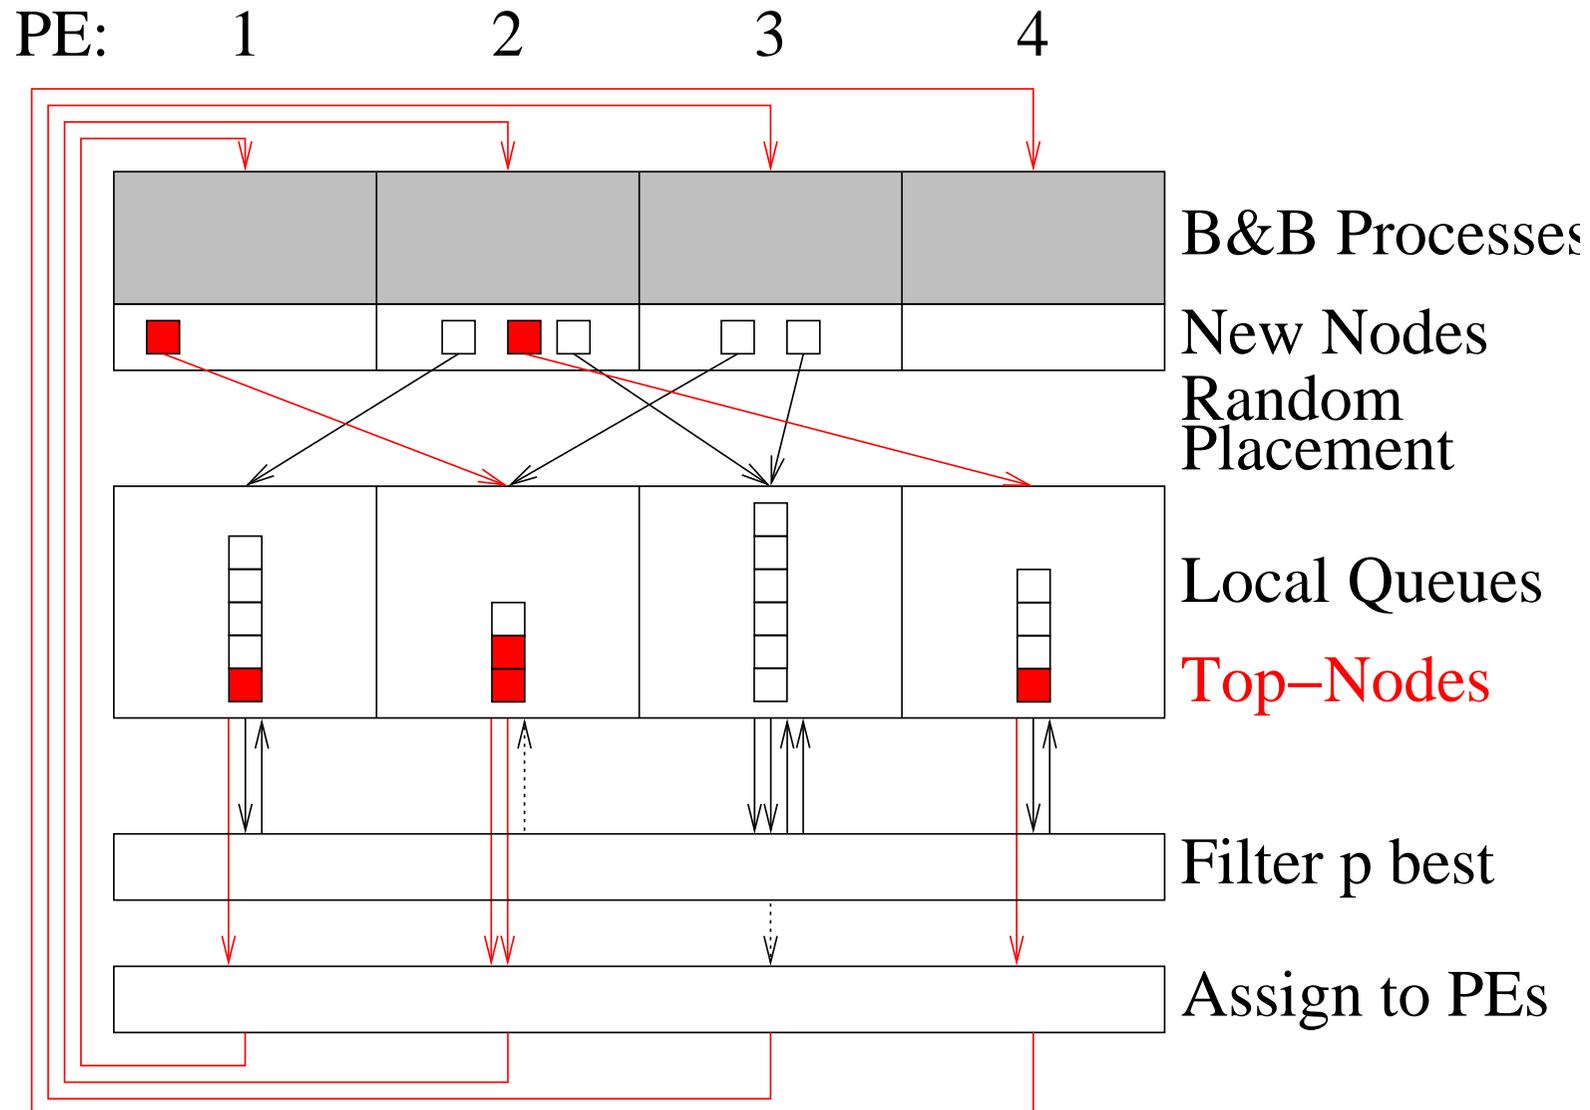


Der Algorithmus von Karp und Zhang

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



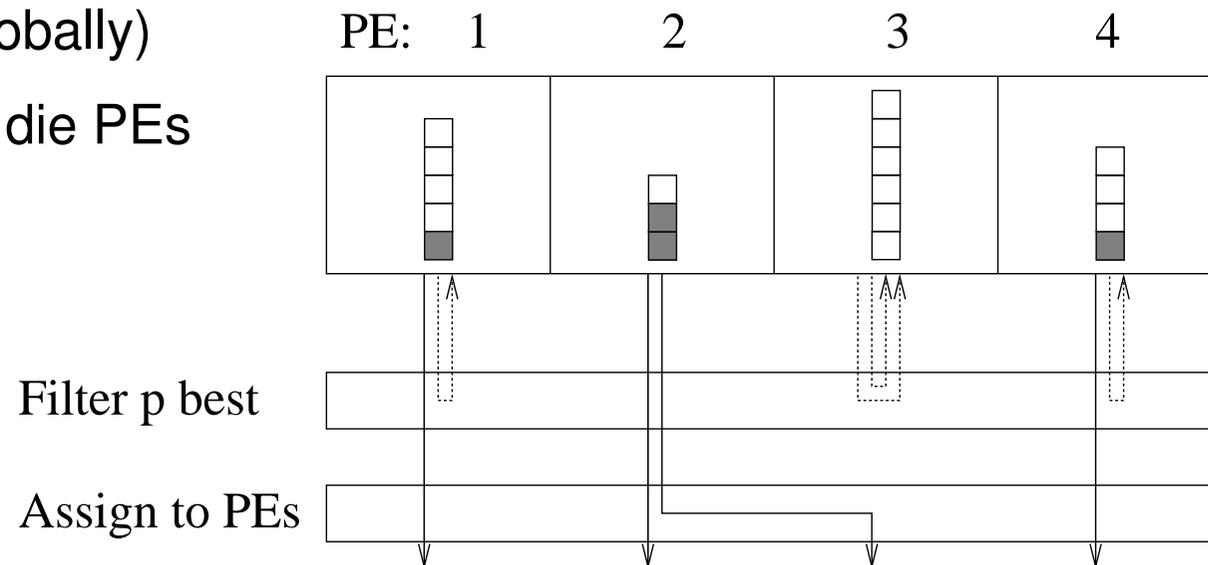
Parallele Prioritätslisten: Ansatz

- 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_{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

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

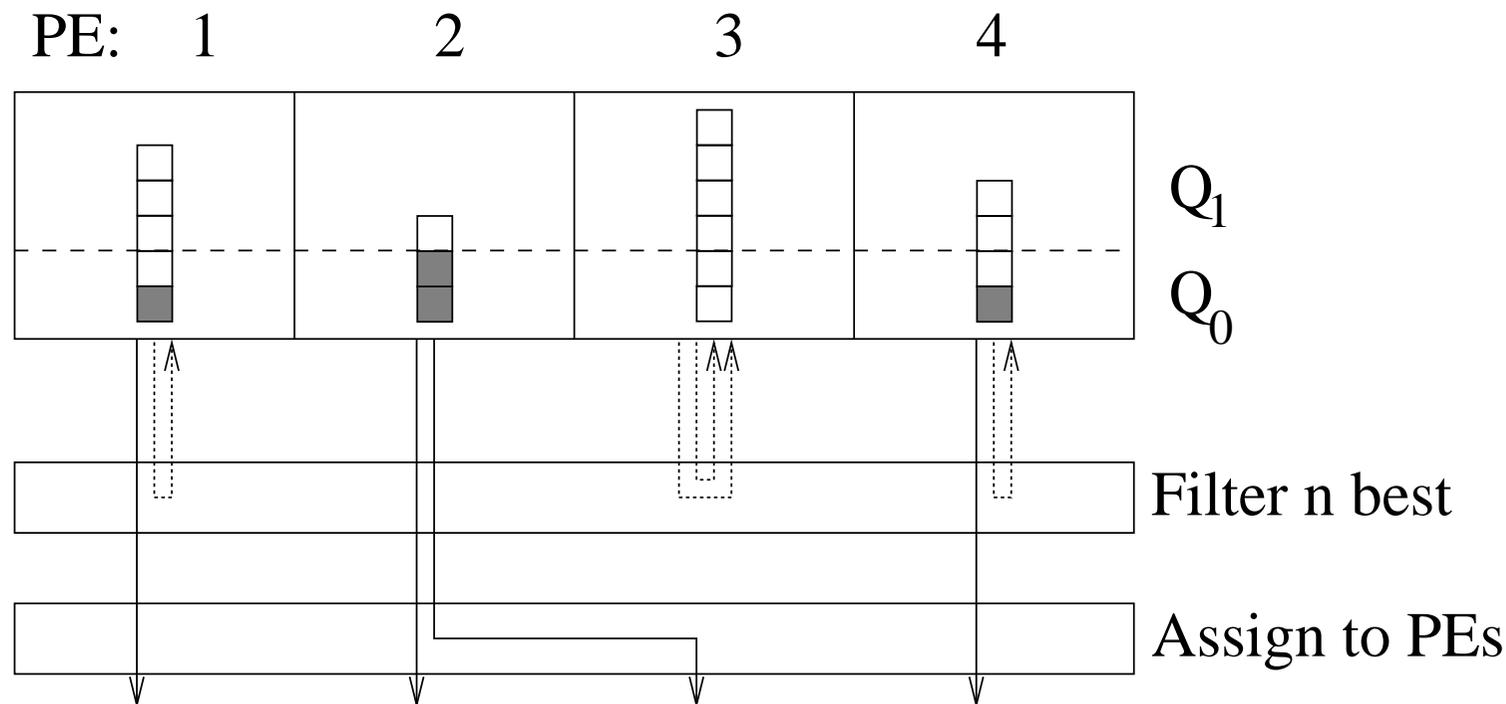
Lokal einfügen: $\mathcal{O}\left(\frac{\log p}{\log \log p} \log \frac{n}{p}\right)$

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_{coll}

Lokal einfügen: **mischen** von Q_0 und neuen Elementen
 $\mathcal{O}(\log p)$ 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 $\mathcal{O}\left(T_{\text{coll}} + \log \frac{n}{p}\right)$

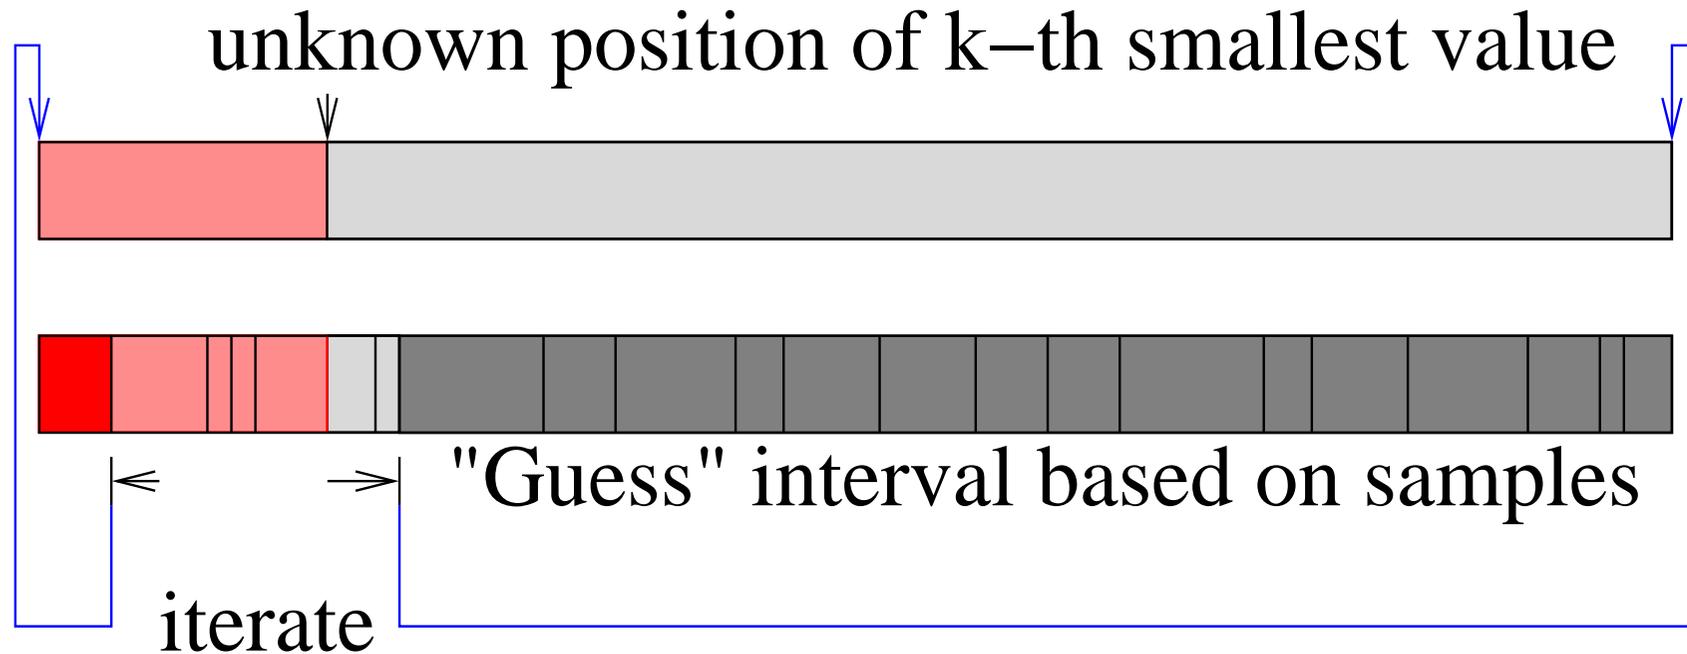
deleteMin*: erwartet $\mathcal{O}\left(T_{\text{coll}} + \log \frac{n}{p}\right)$

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]



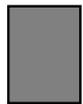
known

unknown

| sample



smallest elements



other elements

Parallele Implementierung

- $|s| = \sqrt{p} \rightsquigarrow$ Sample kann in Zeit $\mathcal{O}(T_{\text{coll}})$ sortiert werden.
- $\Delta = \Theta\left(p^{1/4+\varepsilon}\right)$ für kleine Konstante ε 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 $\mathcal{O}\left(\frac{n}{p} + T_{\text{coll}}\right)$

Parallele 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.

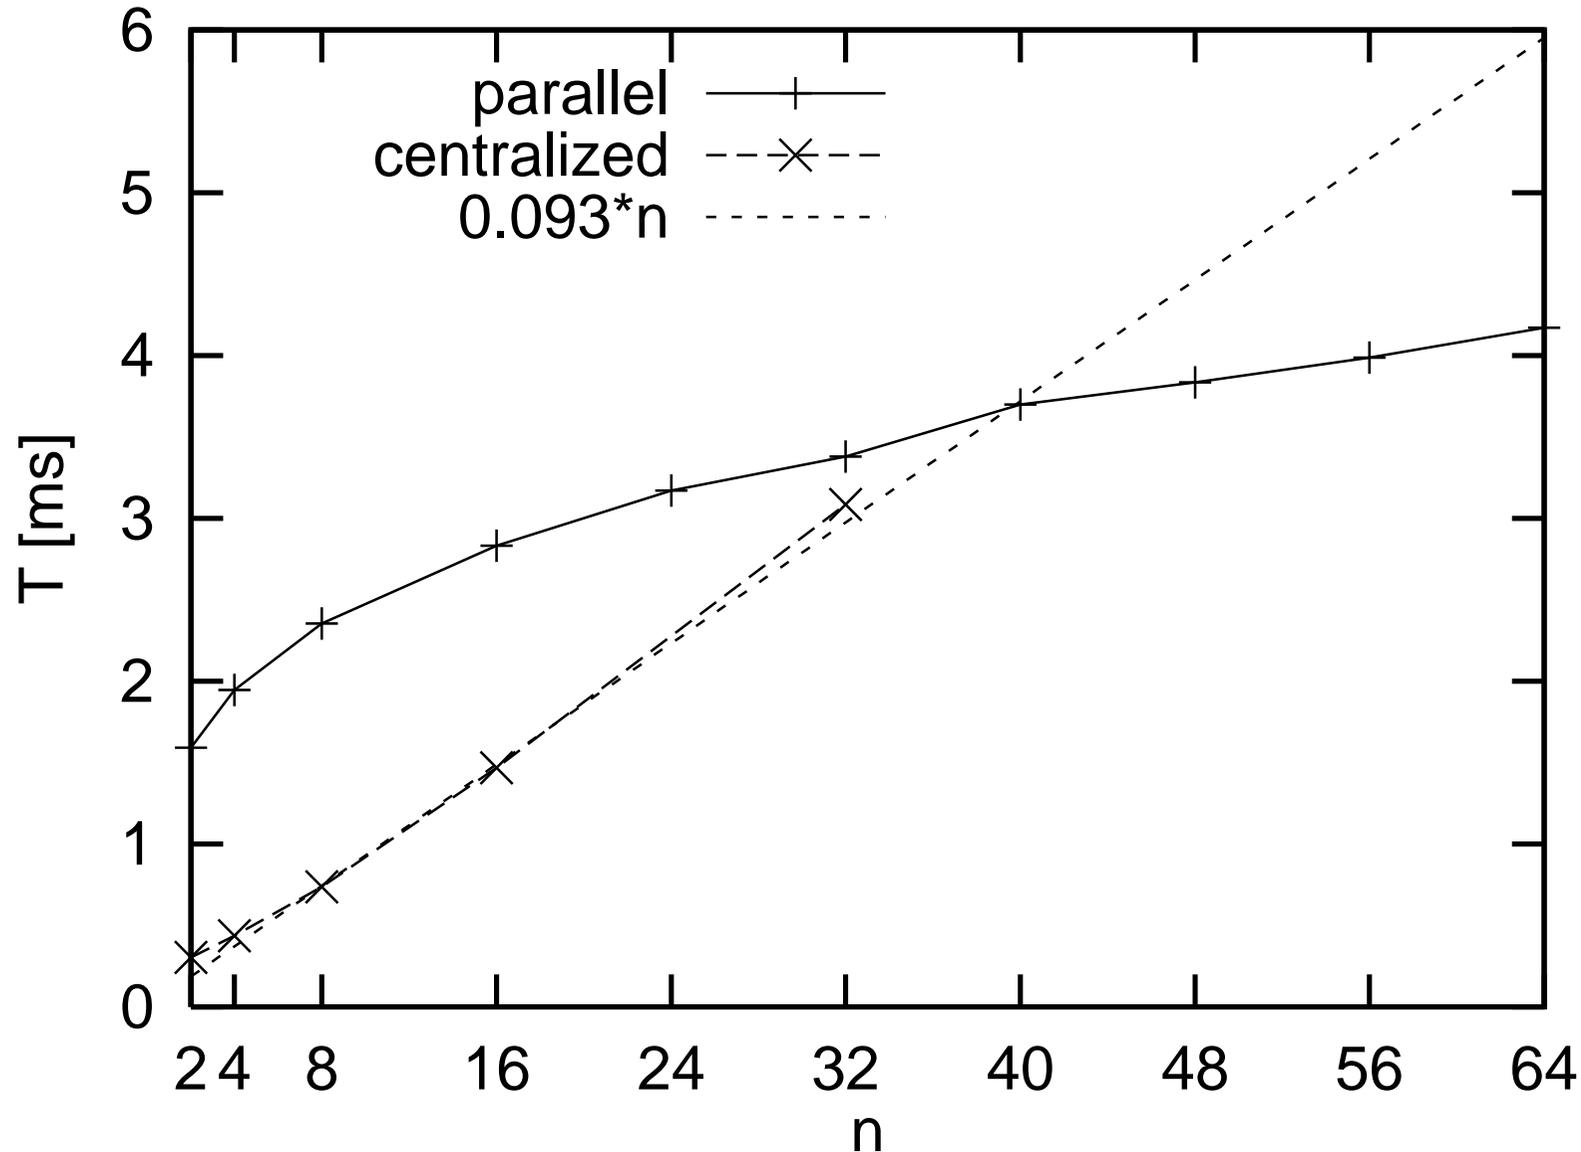
Gelegentlich:

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: $> 28.16\text{ms}$

parallel: 3.73ms

break-even bei 34 PEs

Mehr zu parallelen Priority Queues – Geschichte

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.

Communication Efficient Priority Queues

Each PE stores a **search tree** augmented with subtree sizes. \rightsquigarrow

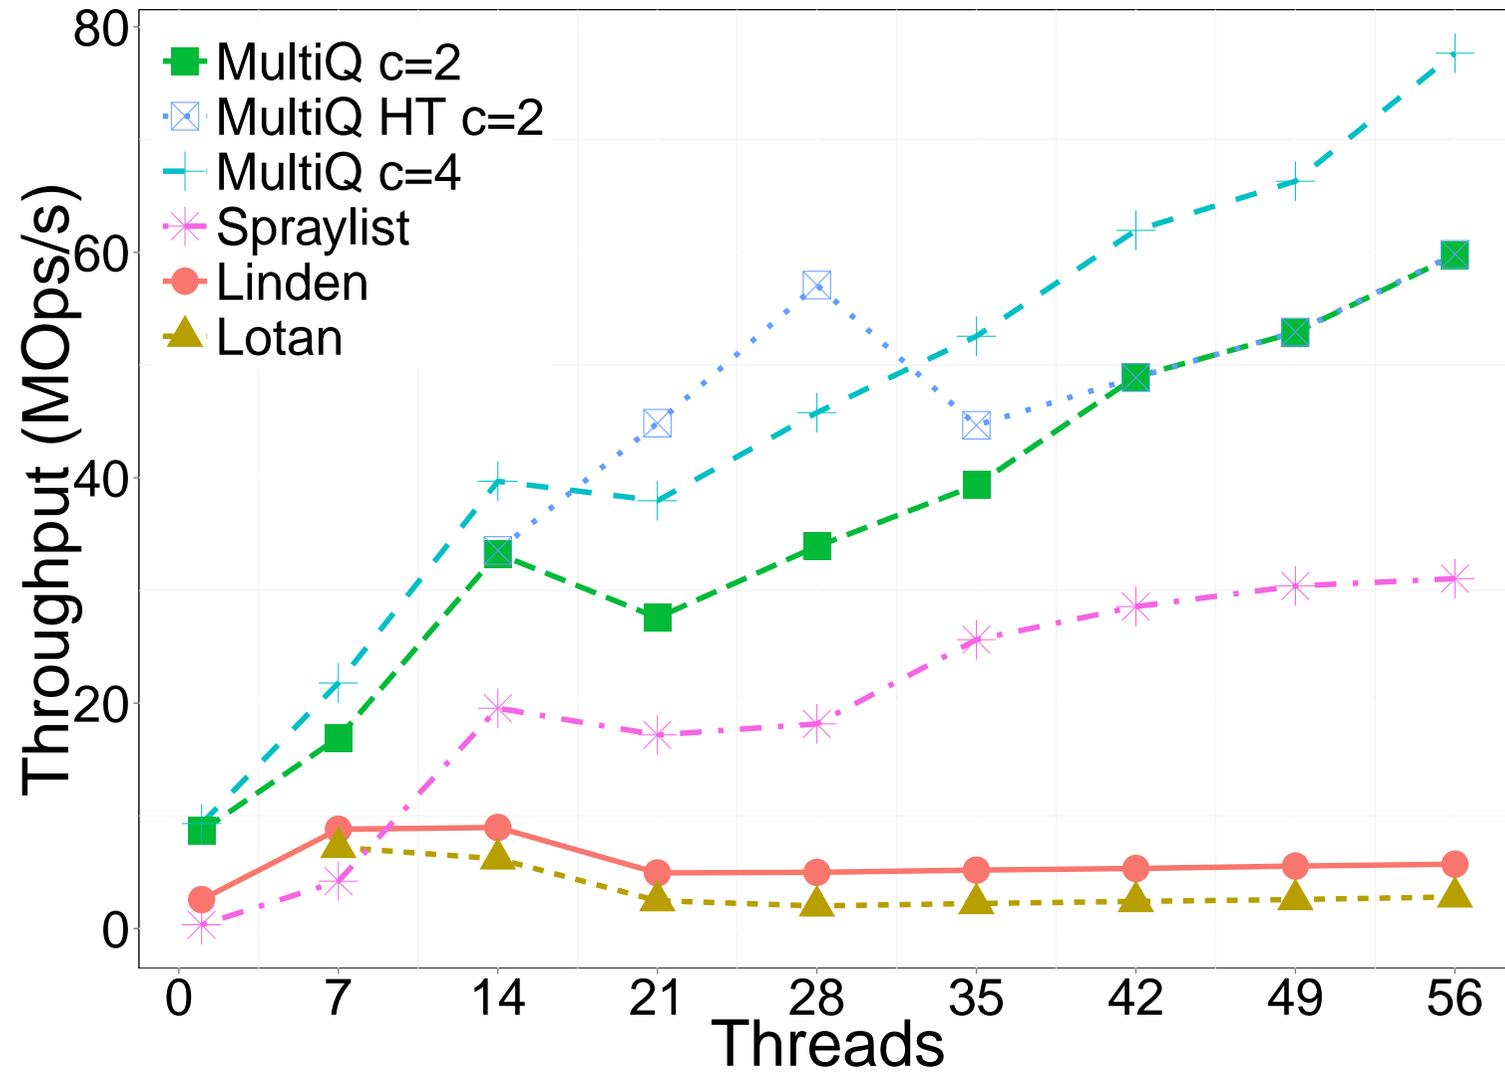
- local insert – $\mathcal{O}(\log n)$ time.
- find k smallest elements in time $\mathcal{O}(\log^2 n)$
(similar to multi-sequence selection for mergesort)
- find $\Theta(k)$ smallest elements in time $\mathcal{O}(\log n)$

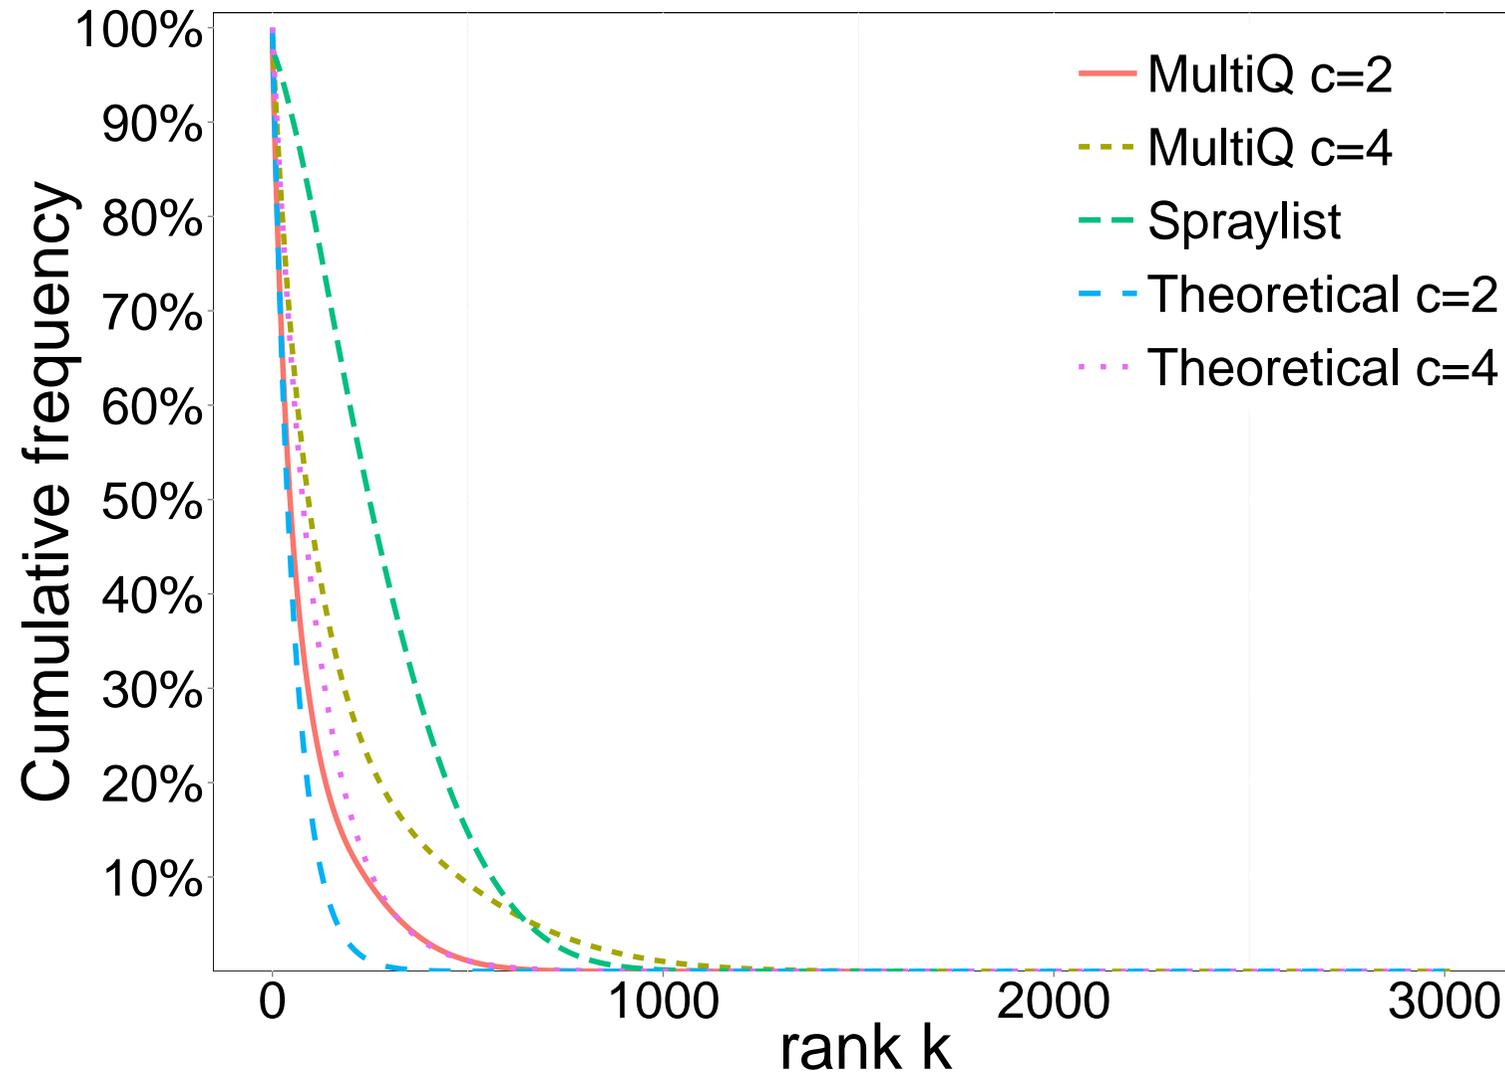
Communication Efficient Algorithms for Top-k Selection Problems, with
Lorenz Hübschle-Schneider, IPDPS 2016

MultiQueues: Simple Relaxed Concurrent Priority Queues

with Roman Dementiev and Hamza Rihani, SPAA 2015

- $2p$ 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

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

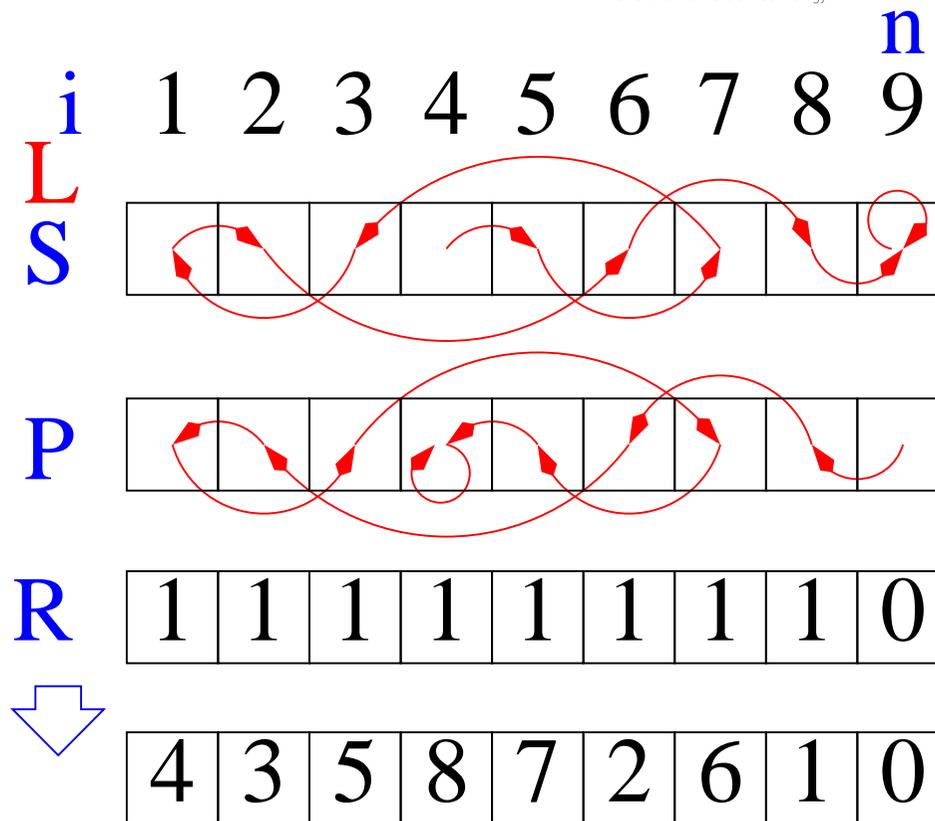
$P(i)$: **Vorgänger** von Element i

Übung: berechne in konstanter Zeit für n PE PRAM

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

Ausgabe: $R(i) =$ Abstand von $S(i)$ 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

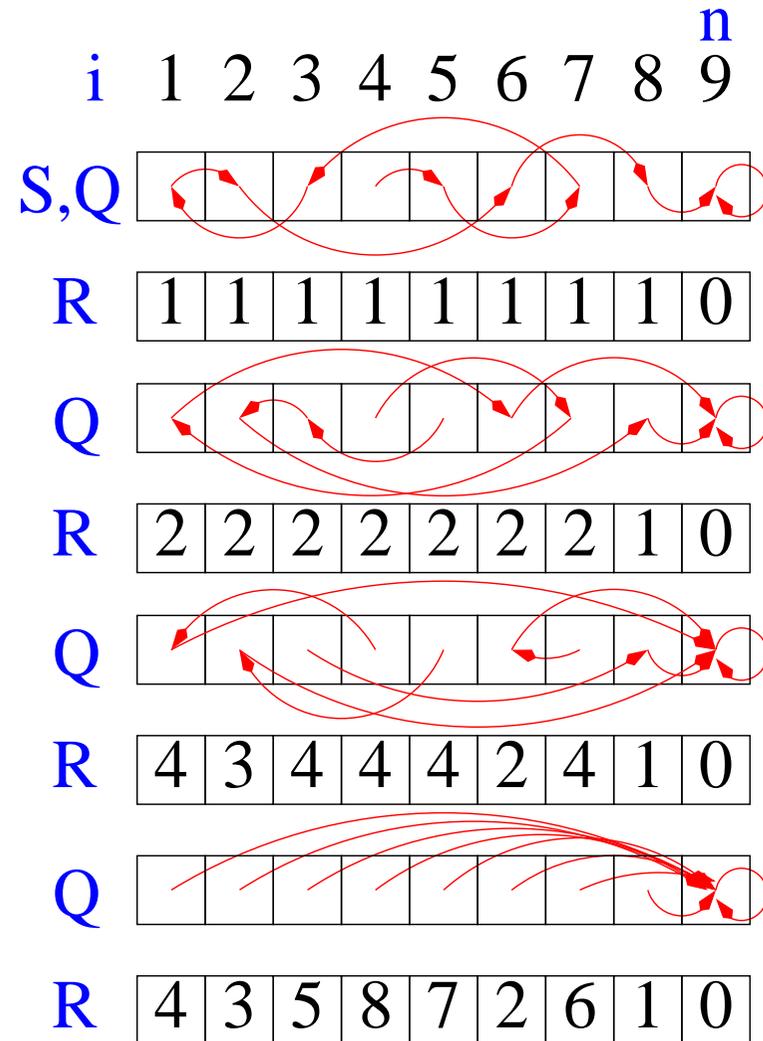
invariant $\sum_{j \in Q_i} R(j) = \text{rank of item } i$

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** $f(S(i))$

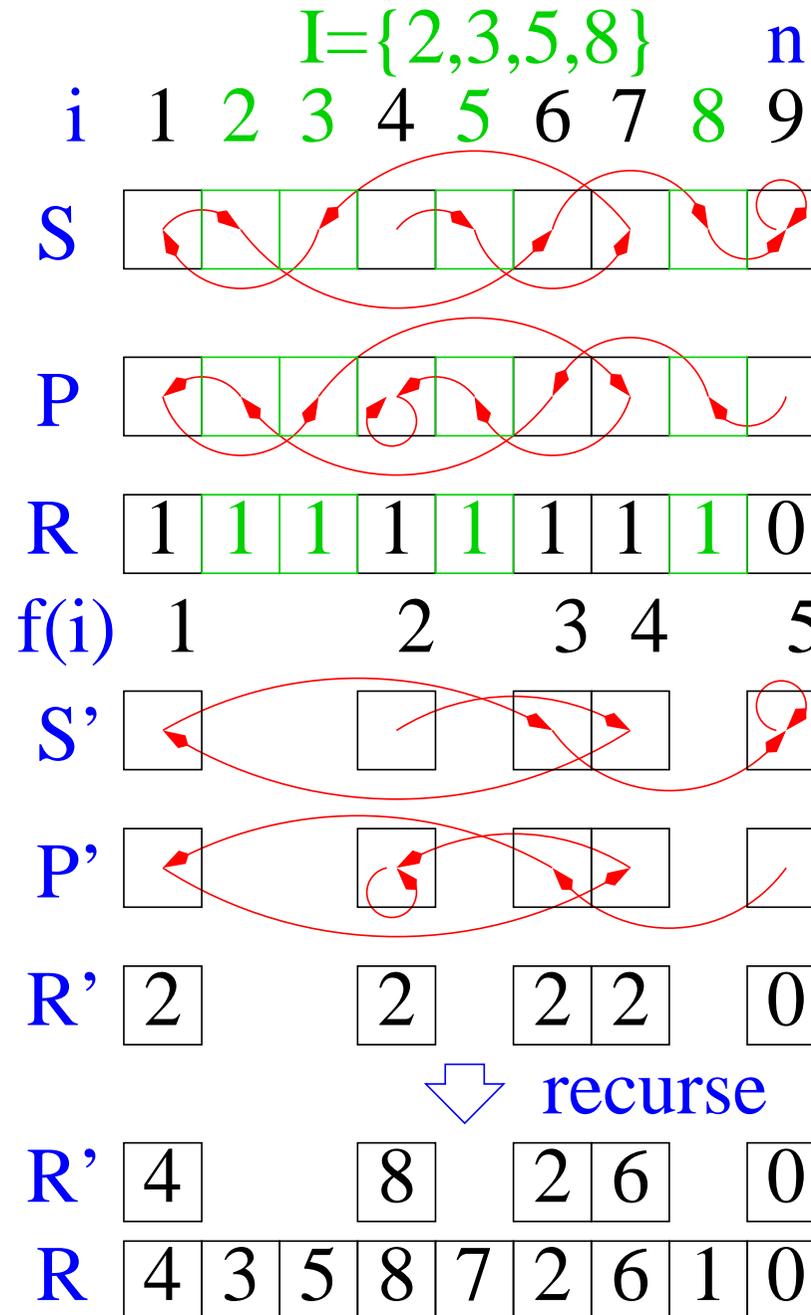
$P'(f(i)) :=$ **if** $P(i) \in I$ **then** $f(P(P(i)))$ **else** $f(P(i))$

$R'(f(i)) :=$ **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** $R(i) := R(i) + R'(f(S(i)))$

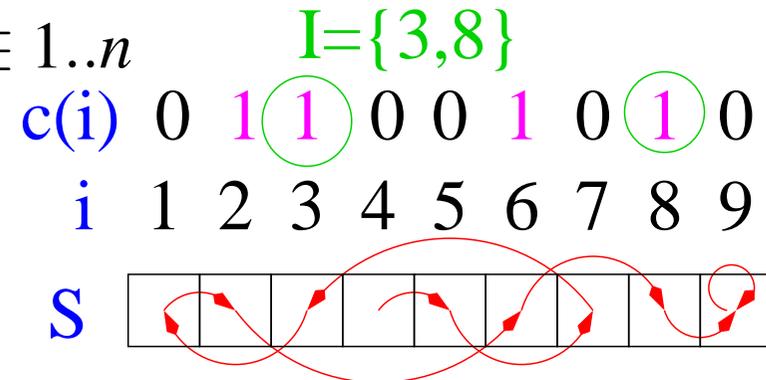


Finden unabhängiger Teilmengen

“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 .

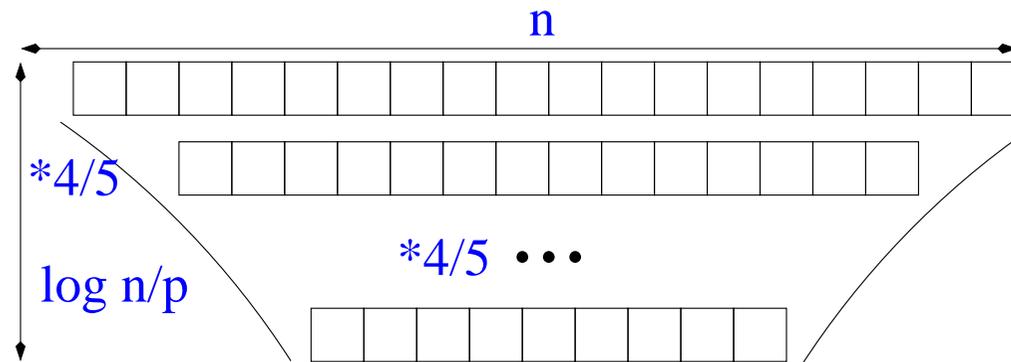
Finden einer bijektiven Abbildung

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 ≈ 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

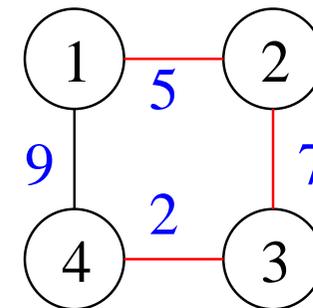
undirected Graph $G = (V, E)$.

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.

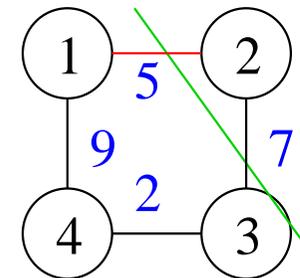
Selecting and Discarding MST Edges

The Cut Property

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

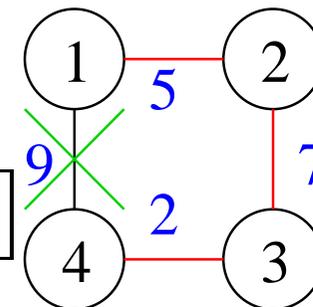
$$C = \{\{u, v\} \in E : u \in S, v \in V \setminus S\}$$

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

$T := \emptyset$

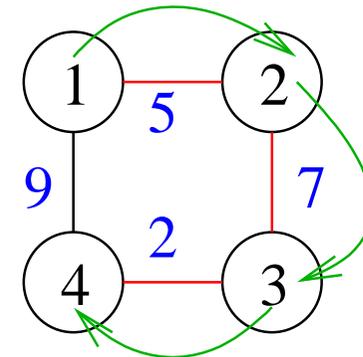
$S := \{s\}$ for arbitrary start node s

repeat $n - 1$ times

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

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

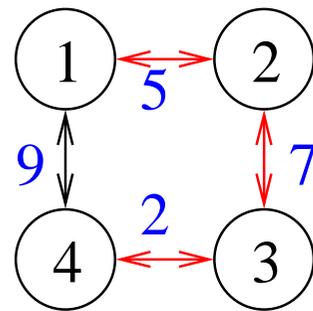
$T := T \cup \{(u, v)\}$



Graph Representation for Jarník-Prim

Adjacency Array

We need node \rightarrow incident edges



	1			n				5=n+1
v	1	3	5	7	9			
E	2	4	1	3	2	4	1	3
c	5	9	5	7	7	2	2	9
	1					m		8=m+1

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)

$\rightsquigarrow \mathcal{O}(m + n \log n)$ 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 α is the inverse

Ackermann function

Problem: still sequential

Best bet: parallelize **sorting**

Idea: grow tree more aggressively

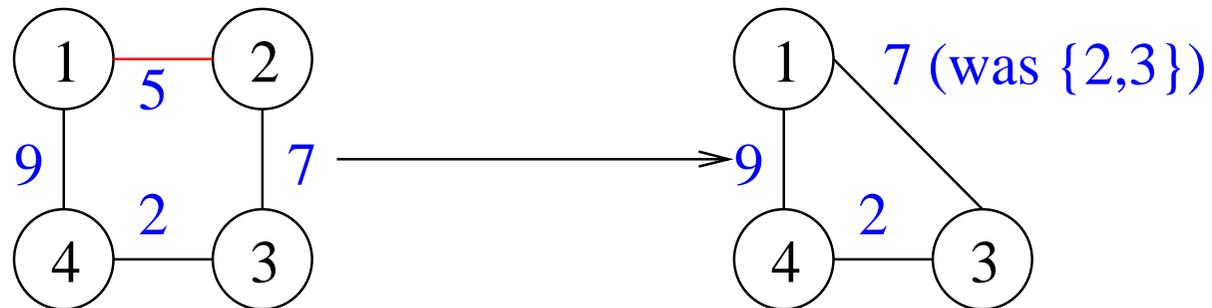
Edge Contraction

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]

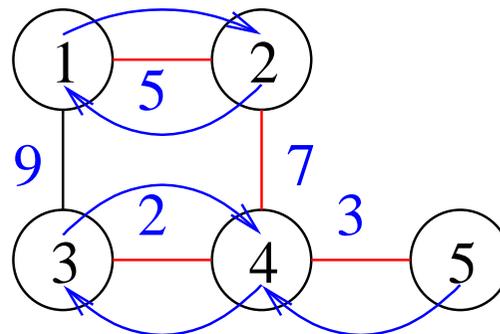
For each node **find** the **lightest** incident edge.

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**

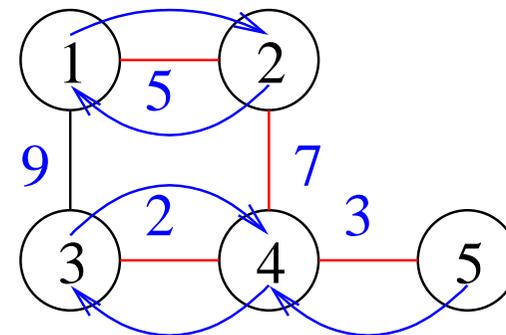
allocate $|\Gamma(v)| \frac{p}{2m}$ processors to node v // prefix sum

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

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

pred(v):= w

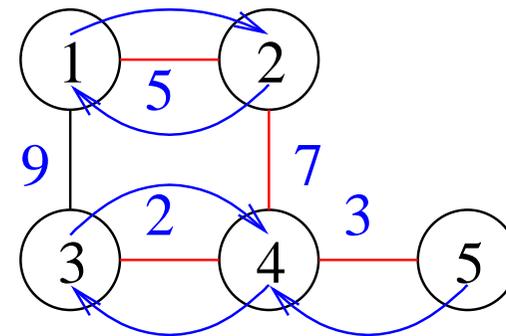
Time $\mathcal{O}\left(\frac{m}{p} + \log p\right)$



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



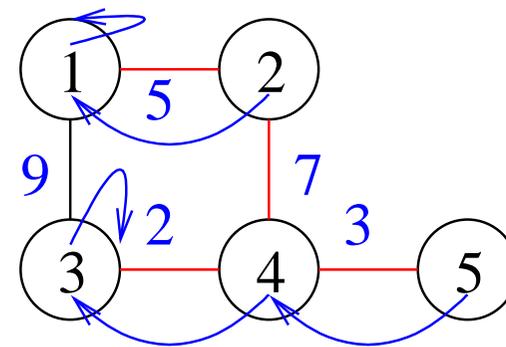
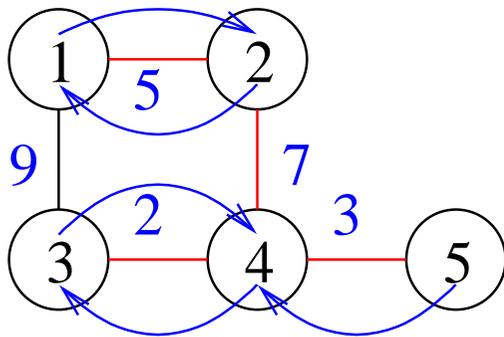
Pseudotrees \rightarrow Rooted Trees

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

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

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

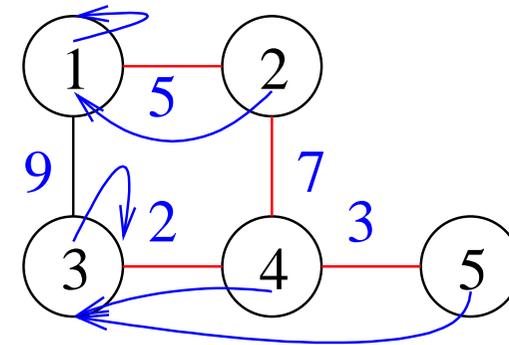
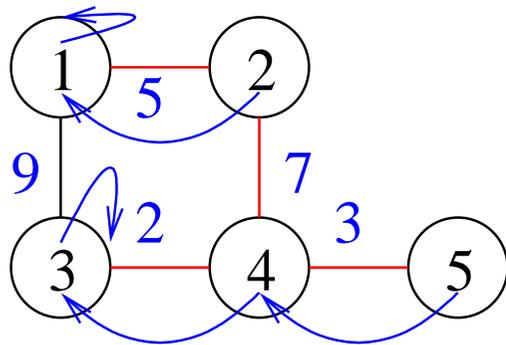
Time $\mathcal{O}\left(\frac{n}{p}\right)$



Rooted Trees \rightarrow 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 $\mathcal{O}\left(\frac{n}{p} \log n\right)$



Contraction

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

$V' = 1..k$

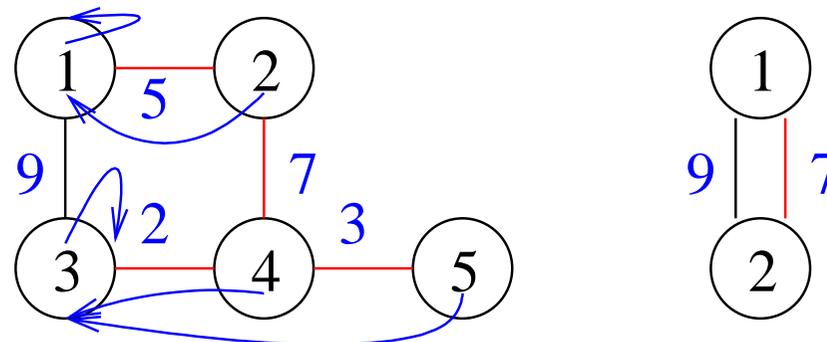
find a bijective mapping $f : \text{star-roots} \rightarrow 1..k$

// 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

Satz 5. *On a CRCW-PRAM, parallel Borůvka can be implemented to run in expected time*

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

- $\leq \log n$ iterations
- sum costs determined above
- for root finding:

$$\sum_i \frac{n}{2^i} \log \frac{n}{2^i} \leq n \log n \sum_i 2^{-i} = \mathcal{O}(n \log n)$$

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

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

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

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

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

Parallel Filter Kruskal

Procedure filterKruskal(E, T : Sequence of Edge, P : UnionFind)

if $m \leq$ 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

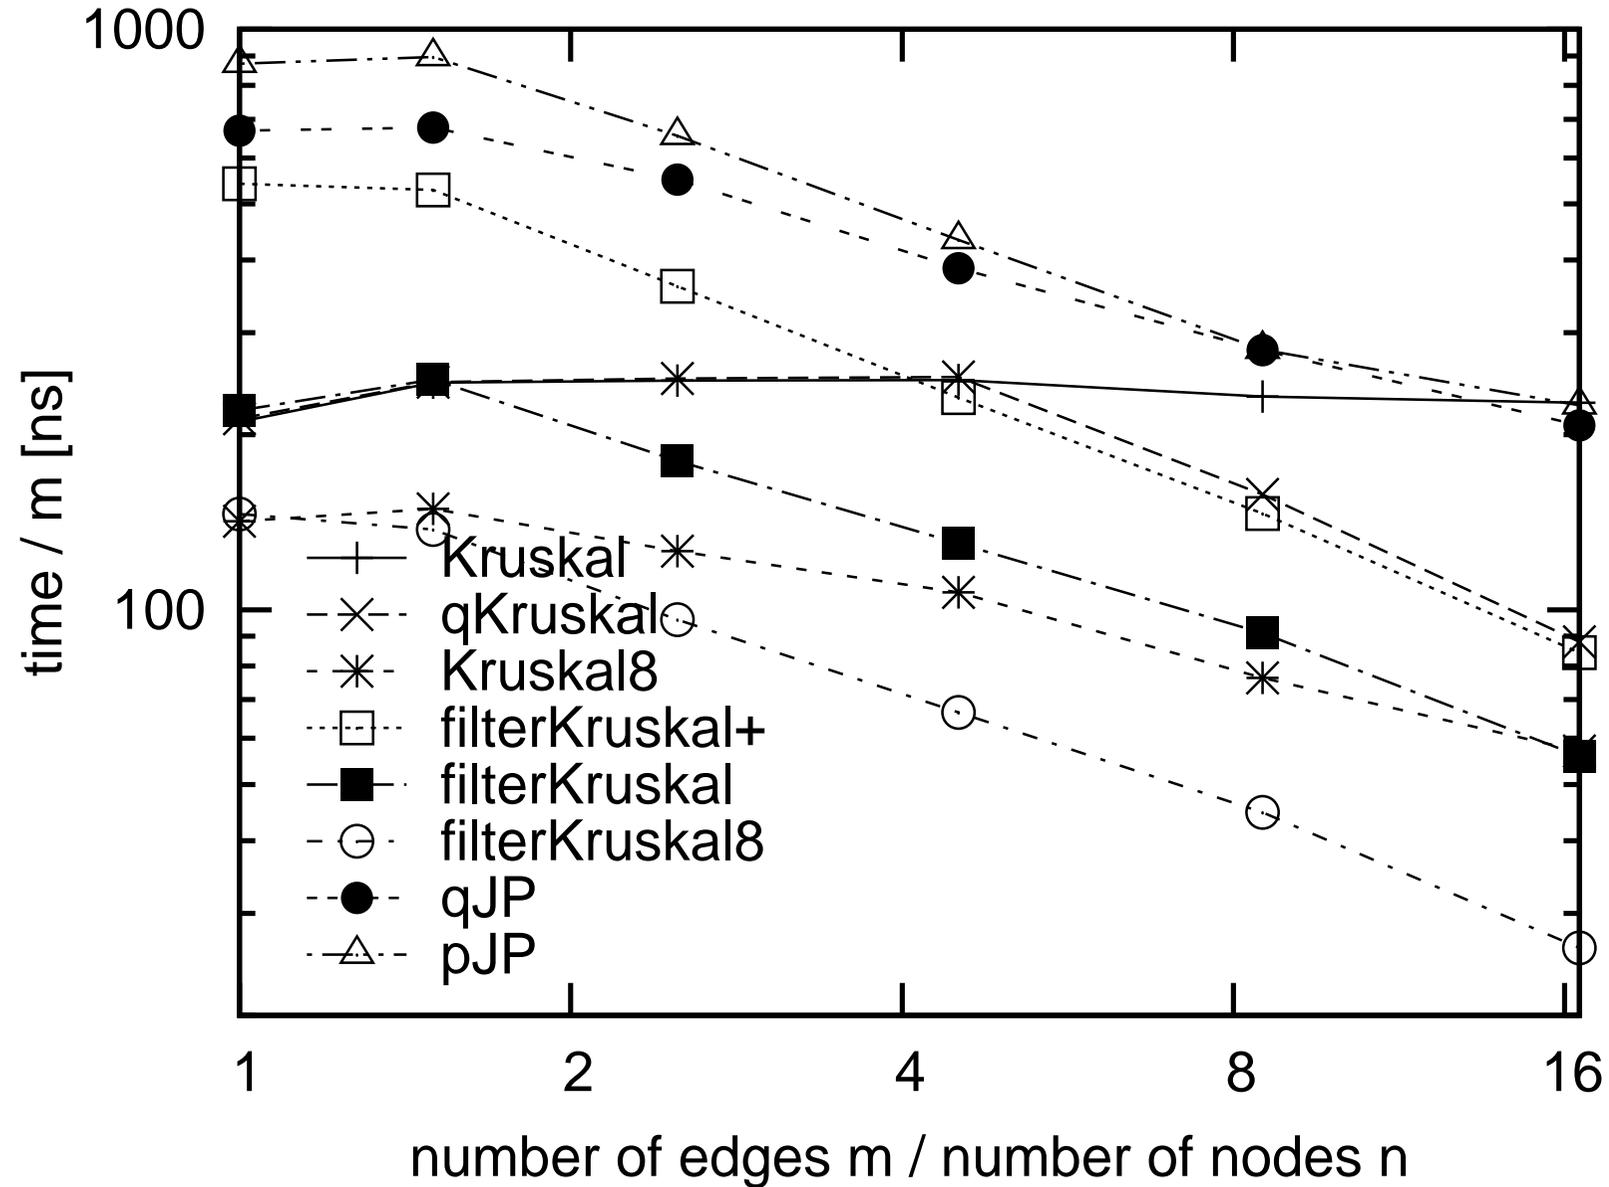
 filterKruskal(E_{\leq}, T, P)

if $|T| = n - 1$ **then** exit

$E_{>} :=$ 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.

[Masterarbeit Wei Zhou 17:] Parallel Borůvka + filtering.

Use edge list representation, union-find.

Speedup up to 20 on 72 cores.

Lastverteilung

[Sanders Worsch 97]

Gegeben

zu verrichtende Arbeit

PEs

Lastverteilung = Zuordnung Arbeit \rightarrow 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: $\max_{i=1}^p \sum_{j \in \text{jobs @ PE } i} T(j, i, \dots)$
- 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

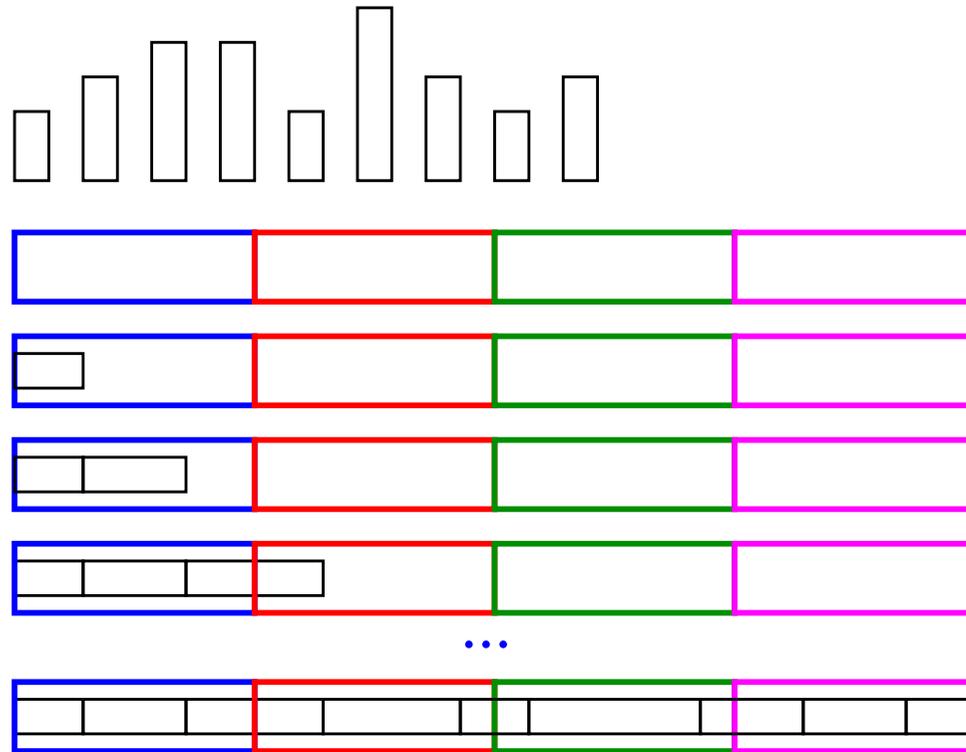
Ein ganz einfaches Modell

- n Jobs, $\mathcal{O}(n/p)$ pro Prozessor, unabhängig, aufspaltbar,
Beschreibung mit Platz $\mathcal{O}(1)$
- Größe l_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 ≤ 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 $j_i \dots j'_i$

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

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

pos := $\sum_{k < i} \ell_k$ // prefix sums

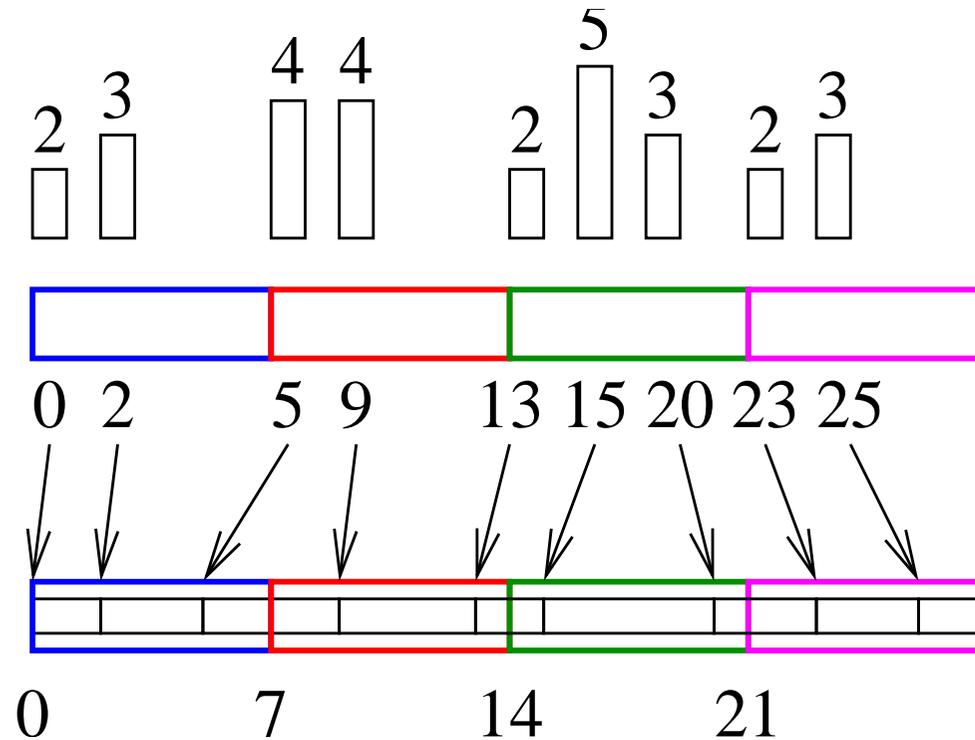
assign job j to PEs $\lfloor \frac{\text{pos}}{C} \rfloor \dots \lfloor \frac{\text{pos} + \ell_j}{C} \rfloor$ // segmented broadcast

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

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

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 $\lfloor \frac{\text{pos}}{C} \rfloor$

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

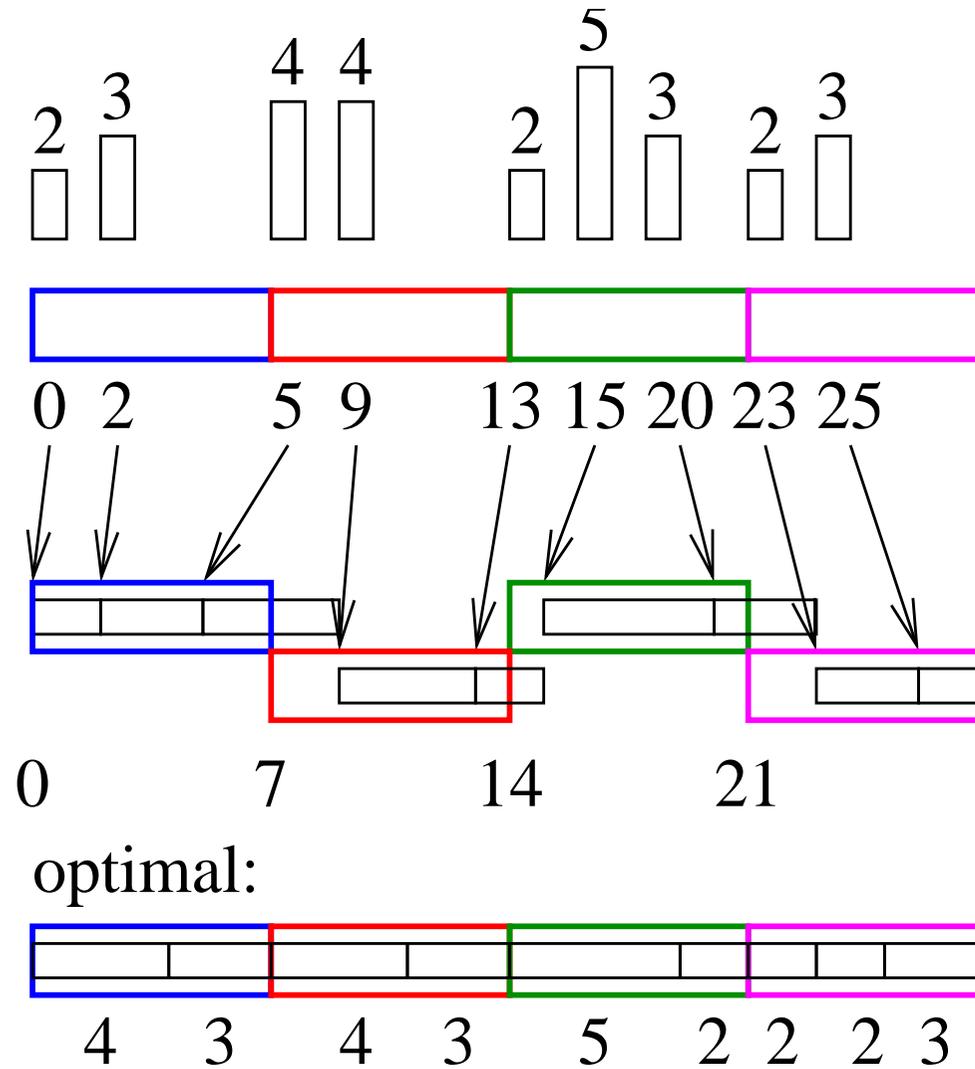
vermutlich nicht parallelisierbar

Parallel

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

[Anderson, Mayr, Warmuth 89]

Atomare Jobs: Beispiel

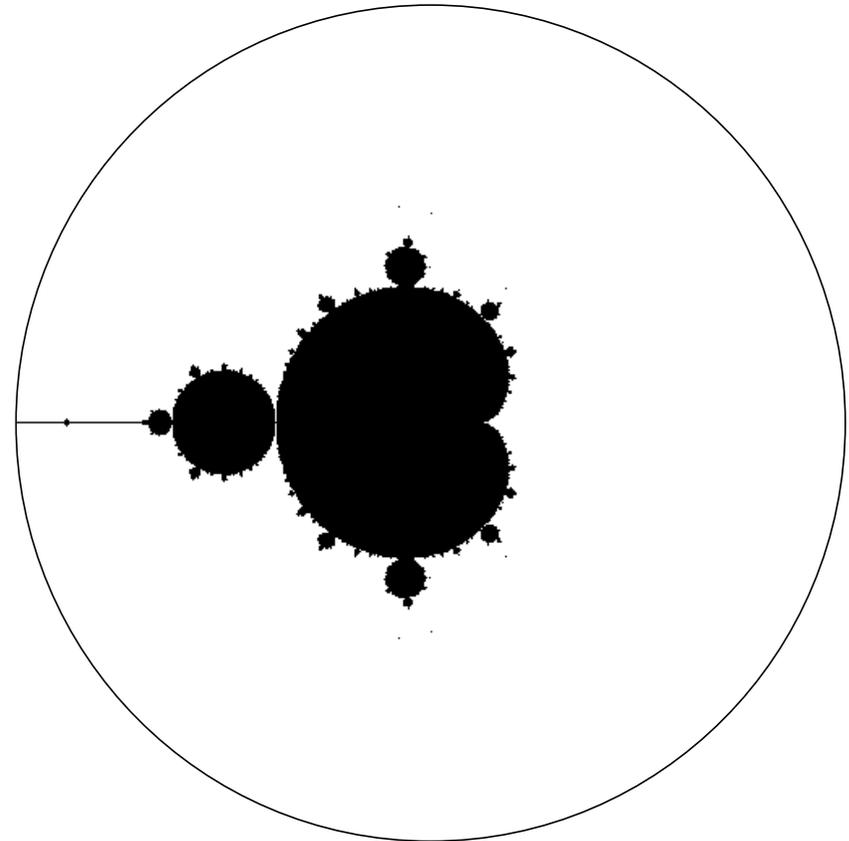


Beispiel Mandelbrotmenge

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

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

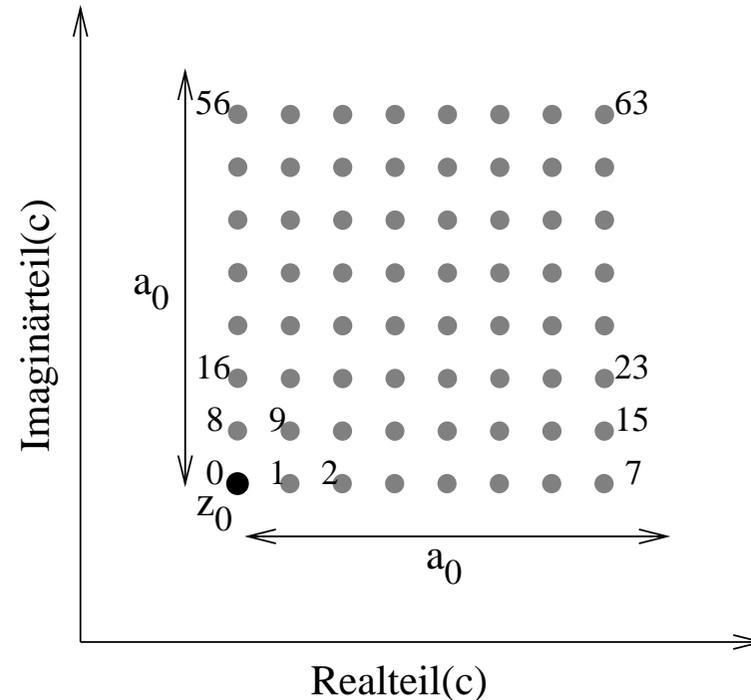
$$M := \{c \in \mathbb{C} : z_c(m) \text{ ist beschränkt}\} .$$



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?



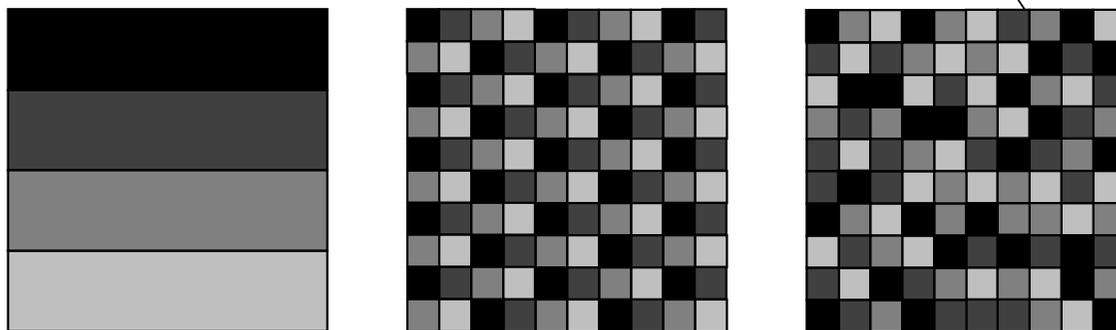
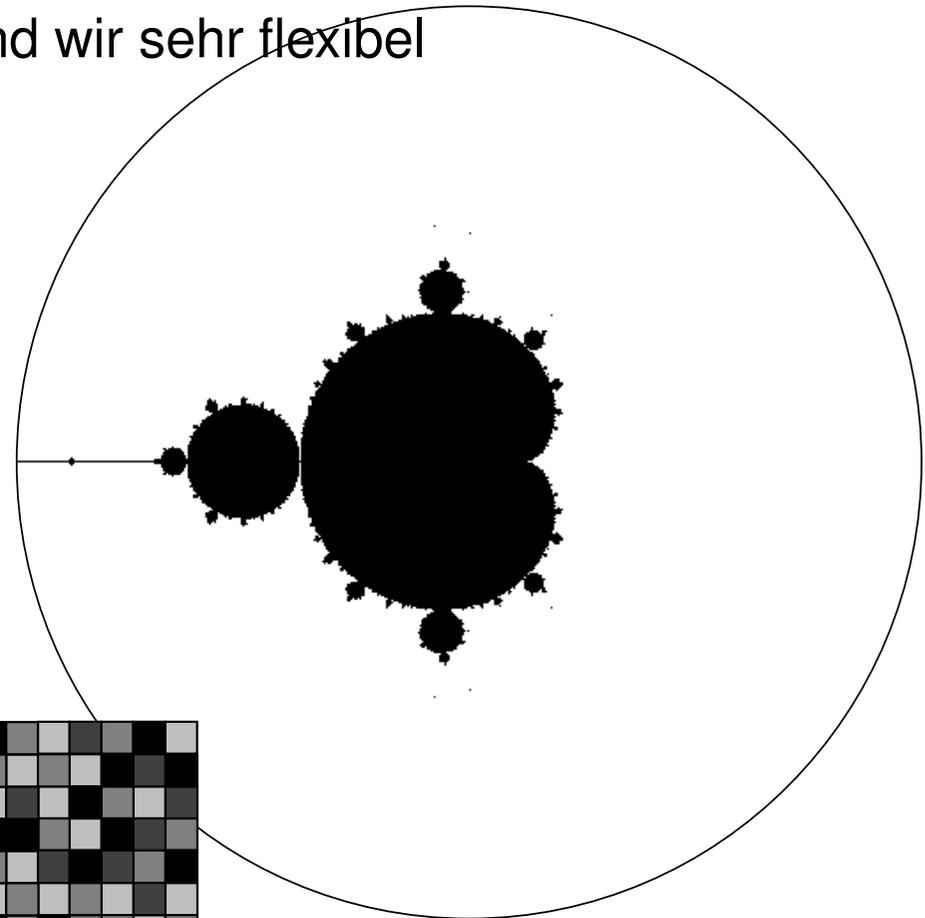
Code

```
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: Parallele 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 ℓ_1, \dots, ℓ_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 $L \geq 2(\beta + 1)pl_{\max} \frac{\ln p}{\epsilon^2} + O(1/\epsilon^3)$

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

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

... Chernoff-Schranken...

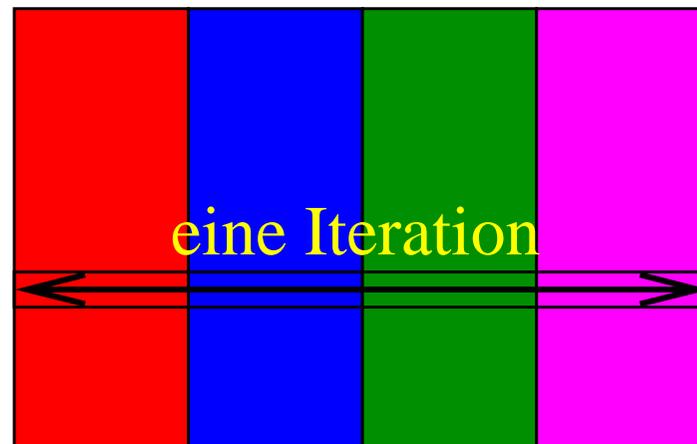
Diskussion

- + 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.)

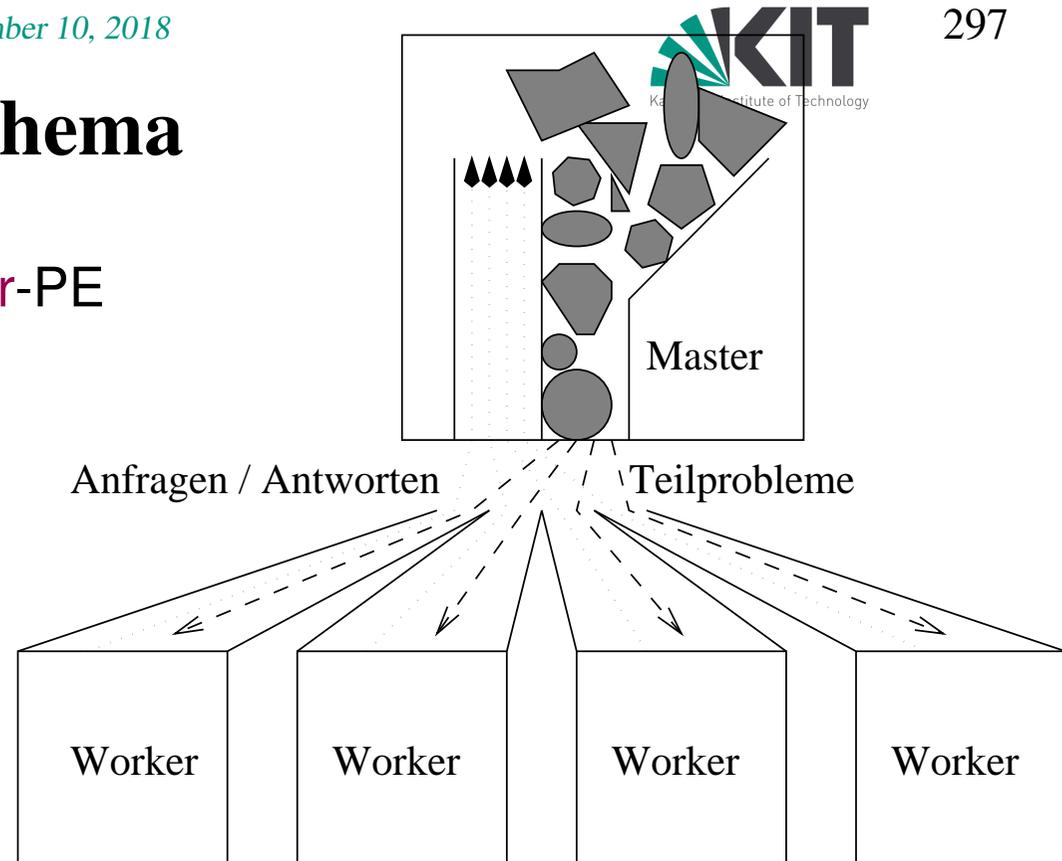
Duenn besetzte Matrix



zufaellig permutierte Spalten

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**)

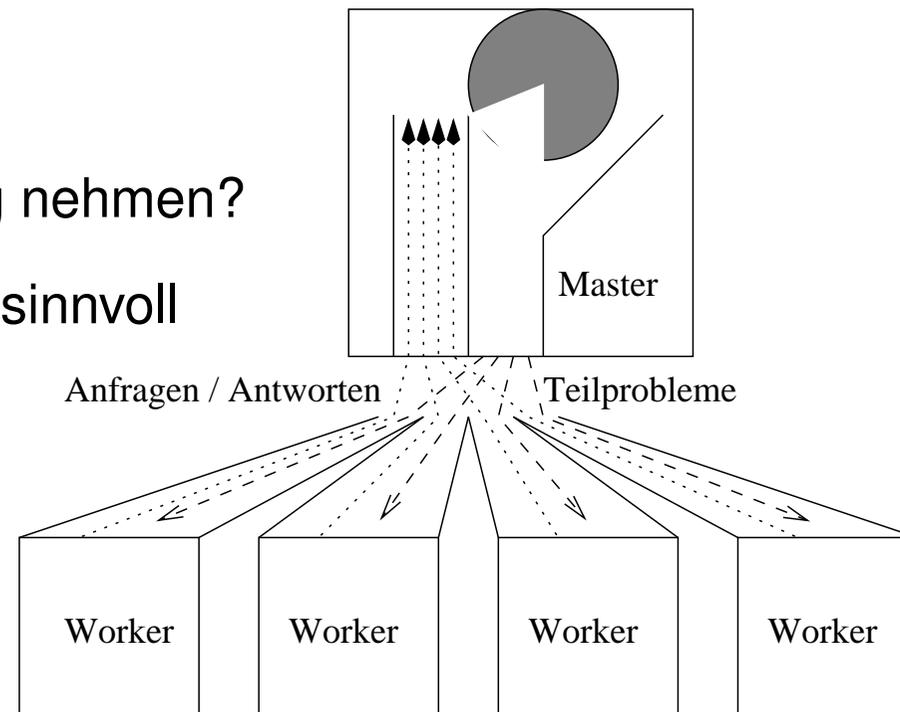


Diskussion

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

Größe der Teilprobleme

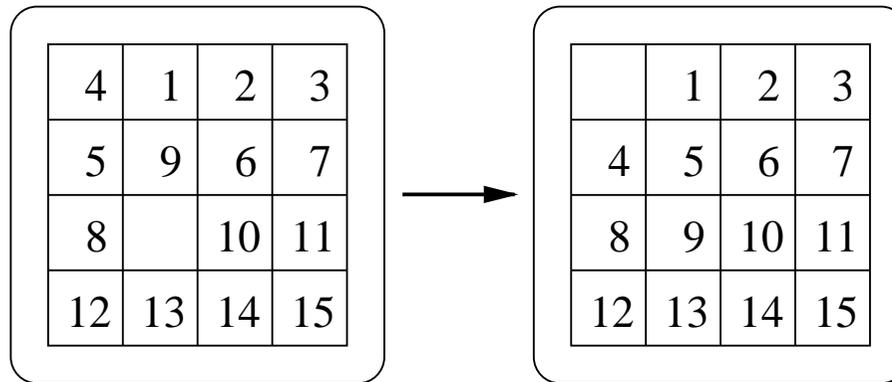
- Möglichst grosse Probleme abgeben solange Lastverteilung nicht gefährdet. Warum?
- Konservatives Kriterium: **obere** Schranke für die Größe des abgegebenen Teilproblems \leq
 $1/P$ -tel **untere** Schranke für Systemlast.
- Woher Grössenabschätzung nehmen?
- Aggressivere Verfahren ggf. sinnvoll



Work Stealing

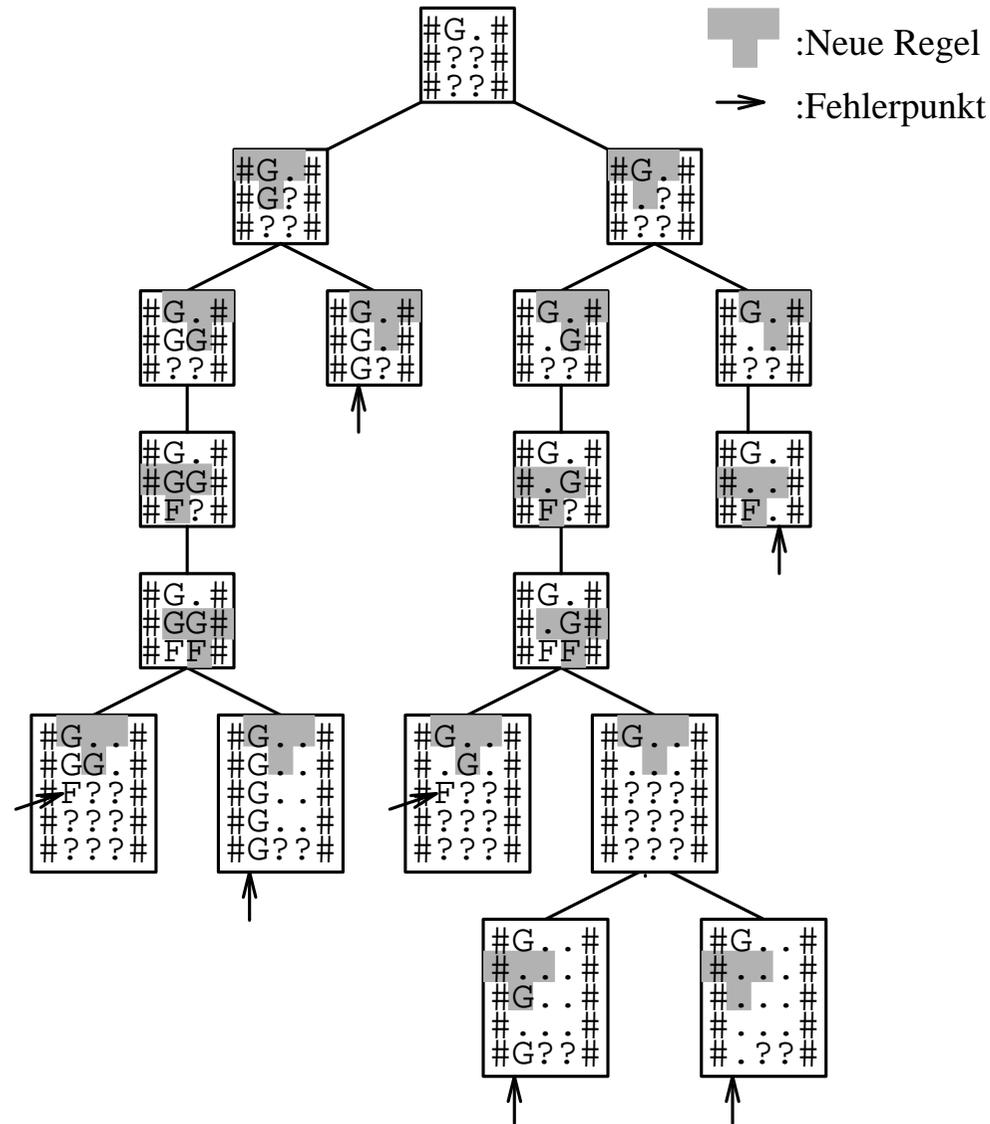
- (Fast) Beliebige unterteilbare Last
- Anfangs alles auf PE 0
- Fast nichts bekannt über Teilproblemgrößen
- Preemption erlaubt. (Sukzessives aufspalten)

Example: The 15-Puzzle



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

Backtracking over Transition Functions

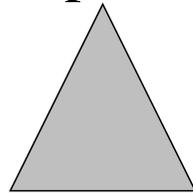


Goal for the analysis

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

An Abstract Model: Tree Shaped Computations

subproblem



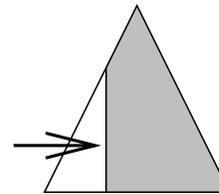
atomic



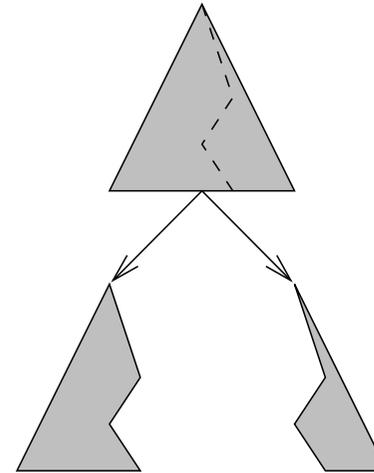
empty



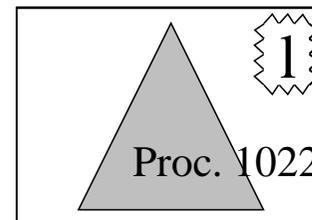
work
sequentially



split



send



Tree Shaped Computations: Parameters

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

T_{split} : max. time needed for splitting

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

ℓ : max size of a subproblem description

p : no. of processors

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

T_{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**

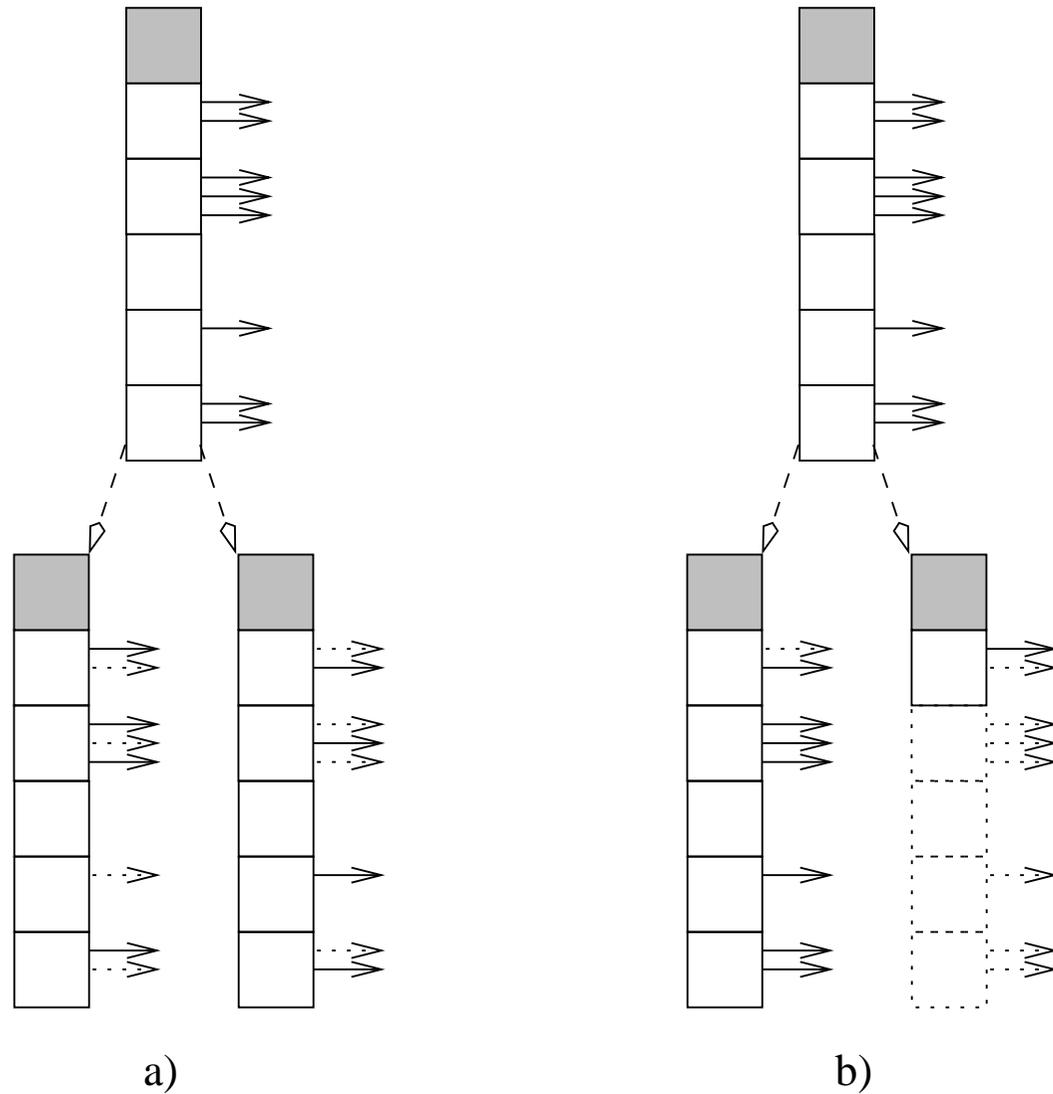
 evaluate leaf N

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. $h \rightsquigarrow T_\infty$

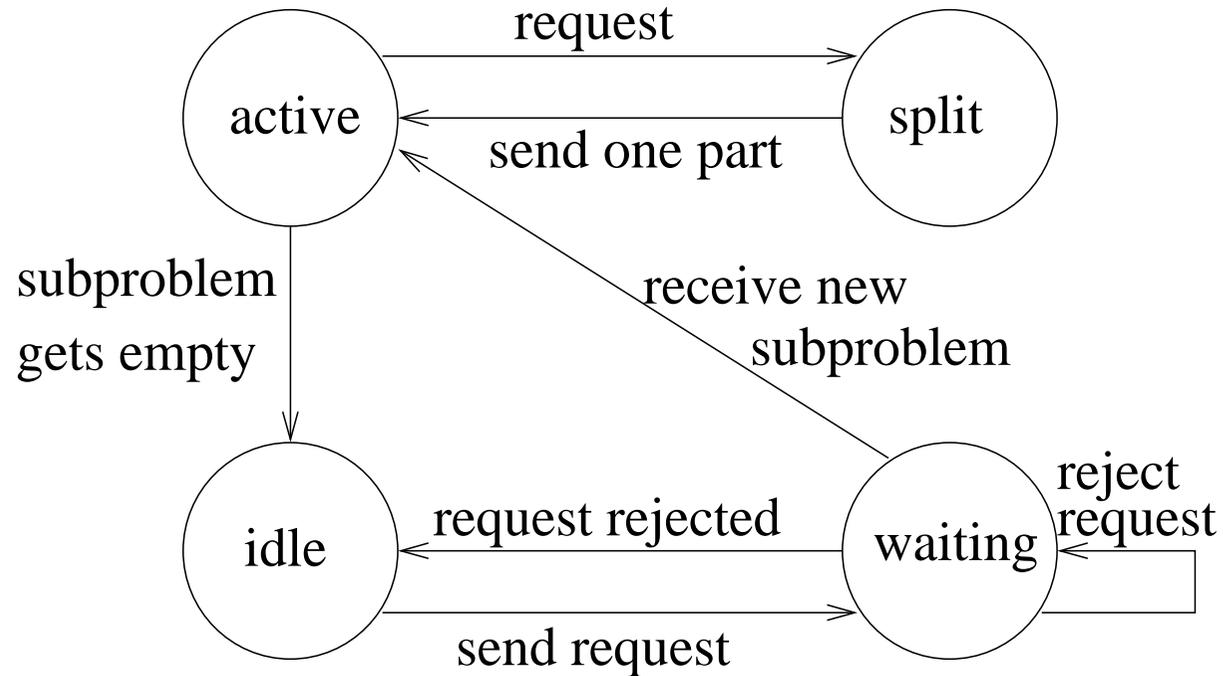
An Application List

- 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

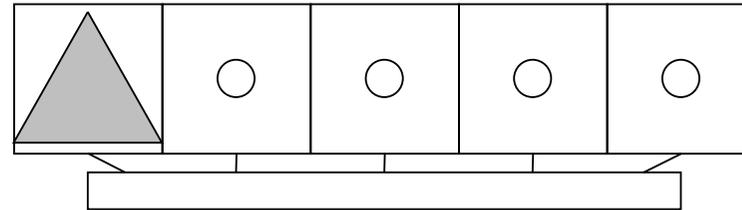
Limits of the Model

- Quicksort and similar divide-and-conquer algorithms (shared memory OK \rightsquigarrow 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

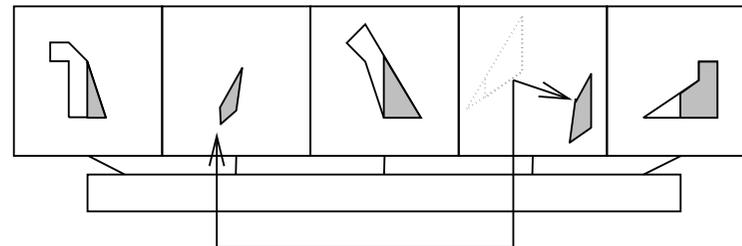
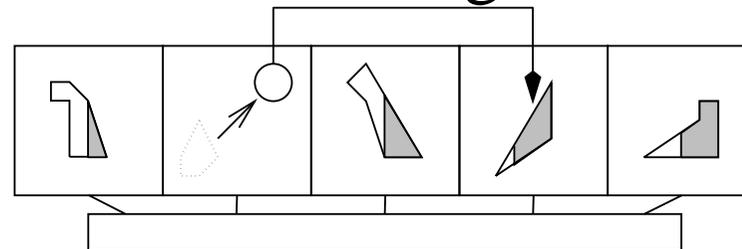


Random Polling



⋮

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

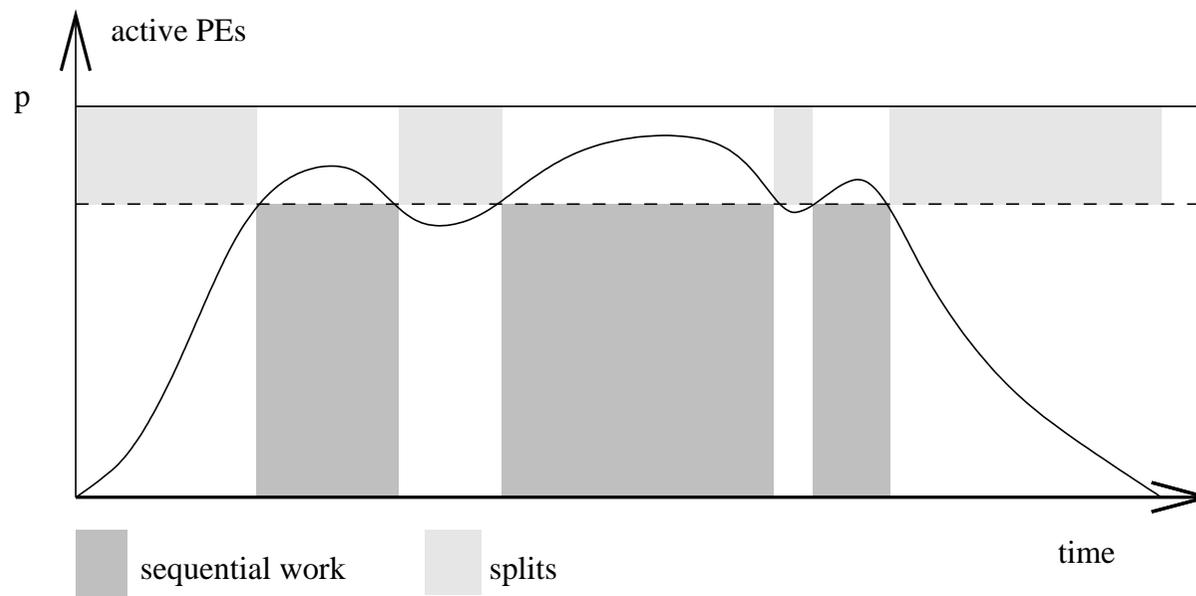
 send empty subproblems the rest

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

Analysis

Satz 6. For all $\varepsilon > 0$ there is a choice of Δt and m such that

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



Bounding Idleness

Lemma 7.

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

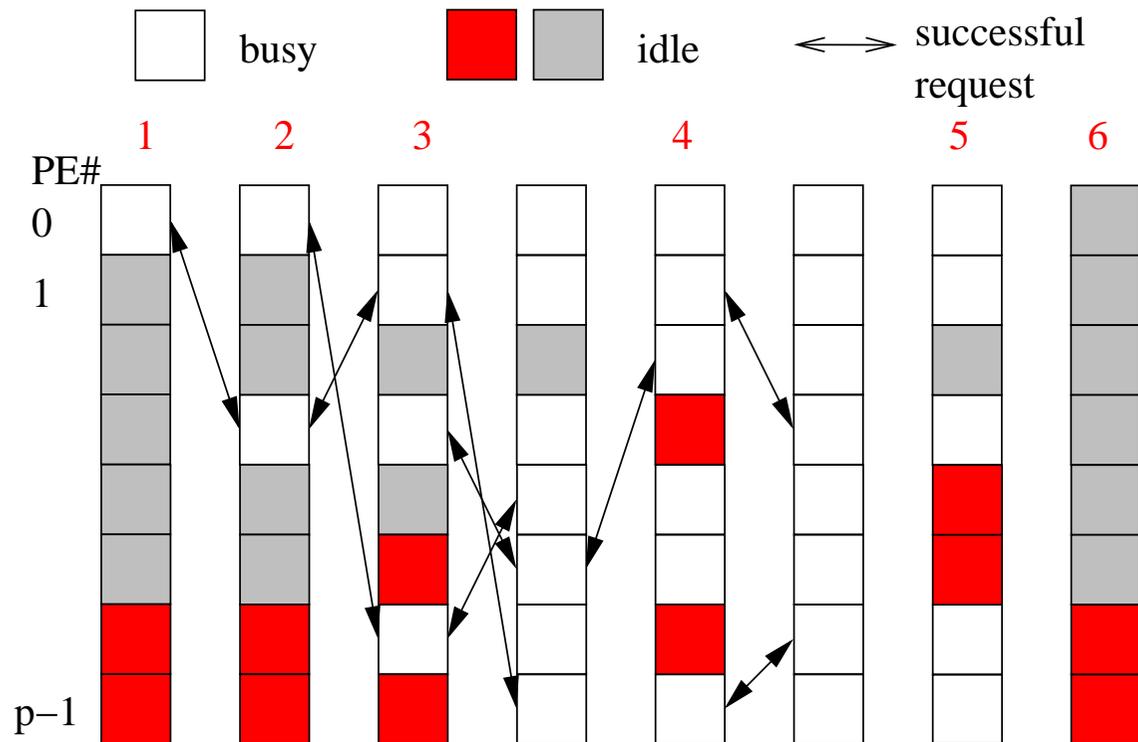
Then $\tilde{O}(h)$ iterations

with at least

m empty subproblems

suffice to ensure

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



Busy phases

Lemma 8. *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

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

while not finished

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

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

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

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

Satz 9. For all $\varepsilon > 0$ there is a choice of Δt 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

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

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 10.

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

for an appropriate choice of Δt .

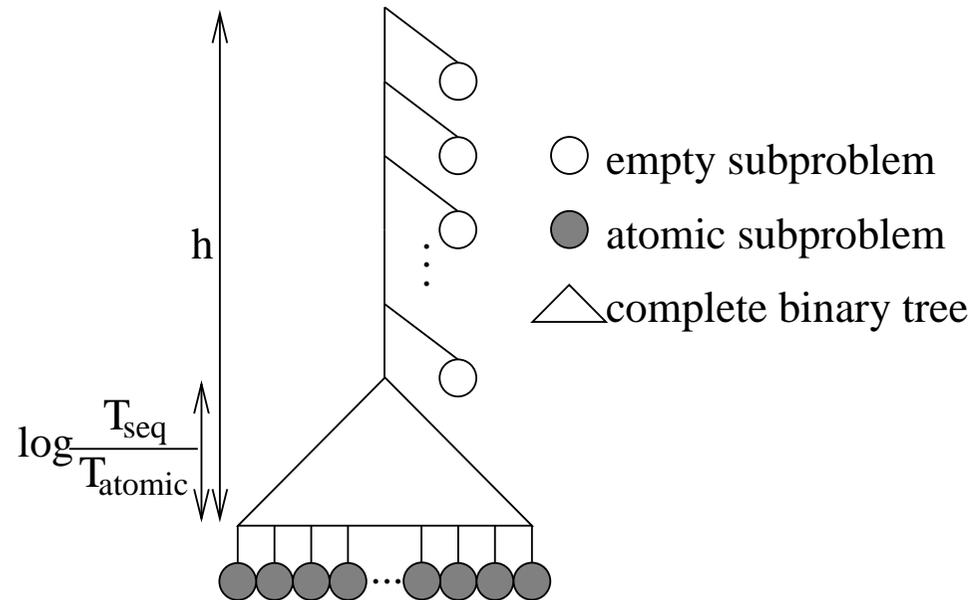
A Trivial Lower Bound

Satz 11. *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

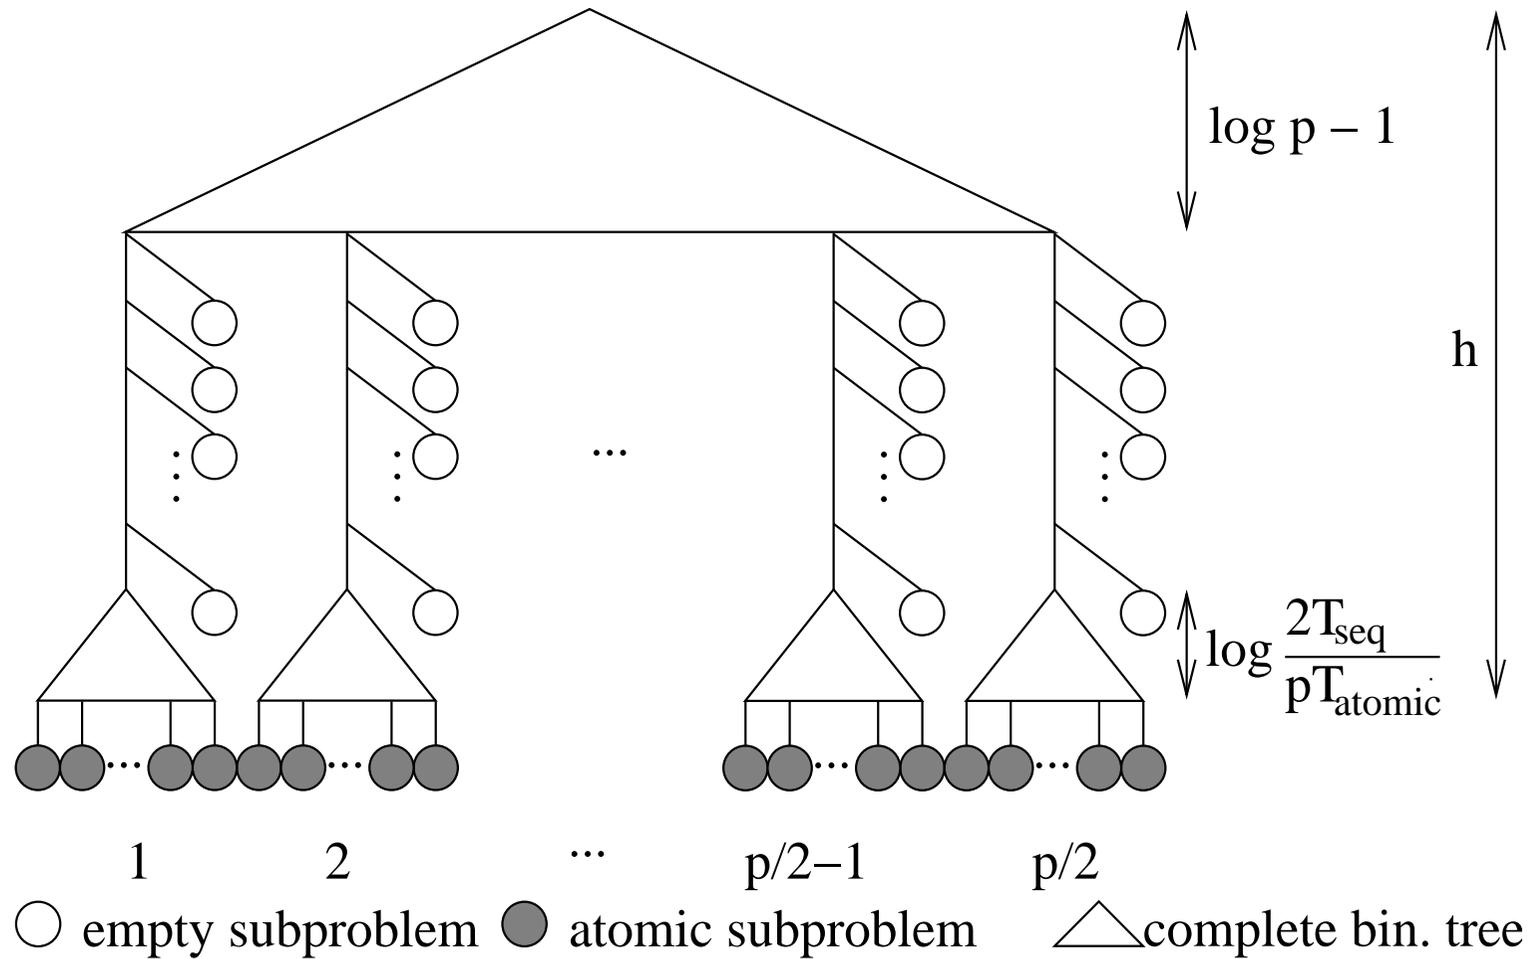


Additional

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

term.

Many Splits Overall



Satz 12. *Some problems need at least*

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

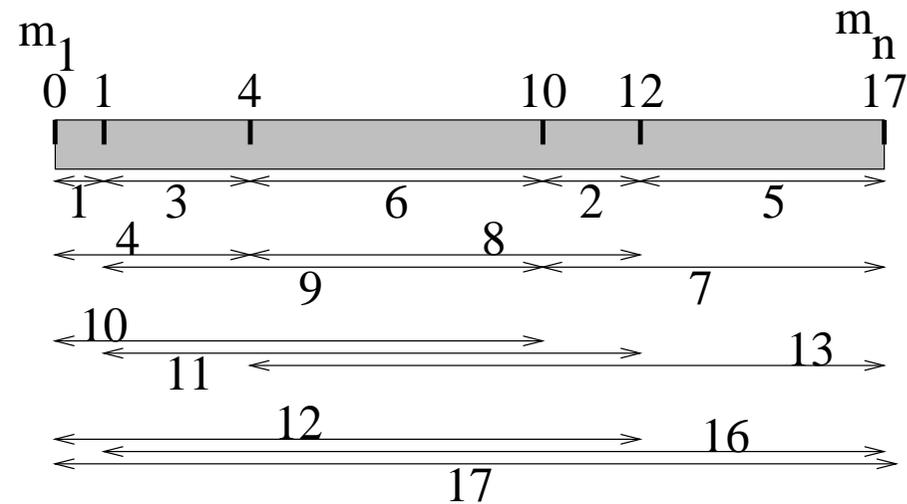
splits for efficiency $\geq \frac{1}{2}$.

Korollar 13. *Receiver initiated algorithms need a corresponding number of communications.*

Satz 14 (Wu and Kung 1991). *A similar bound holds for all deterministic load balancers.*

Golomb-Rulers

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

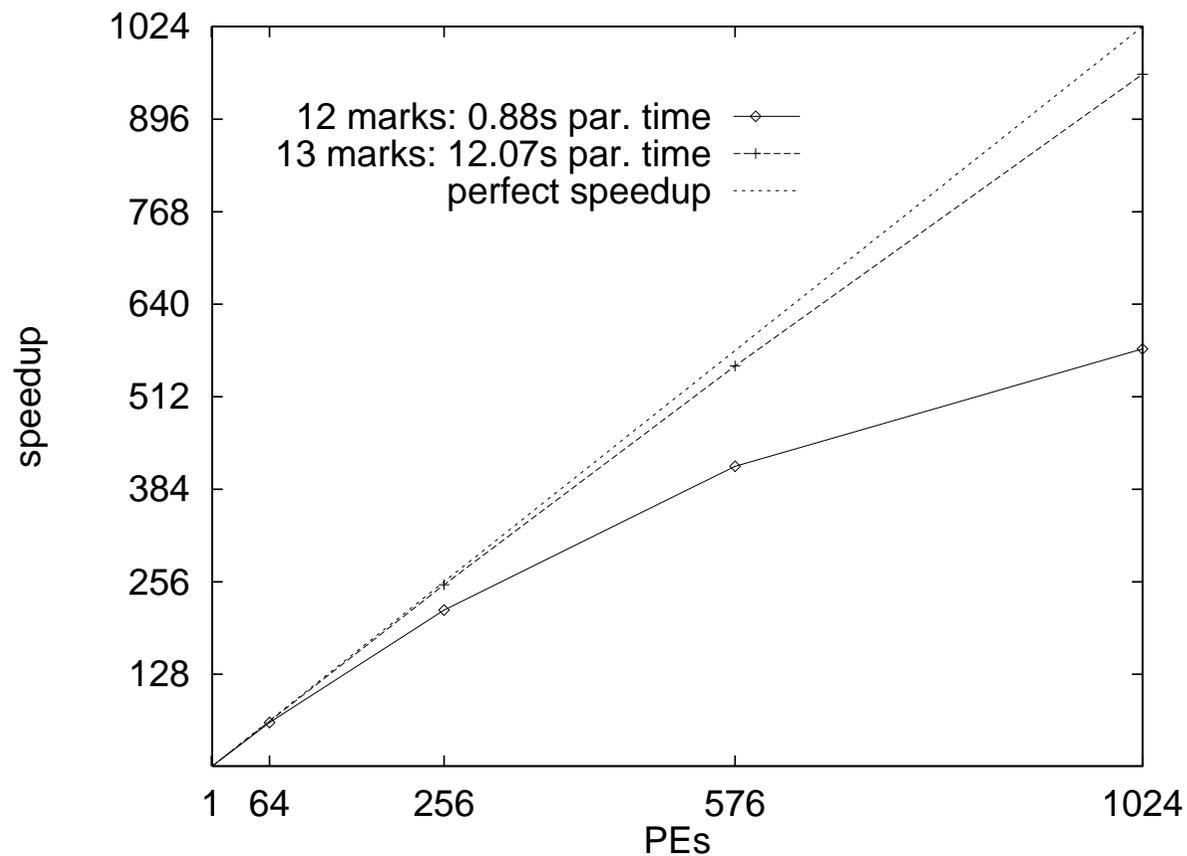


Applications: Radar astronomy, codes, ...

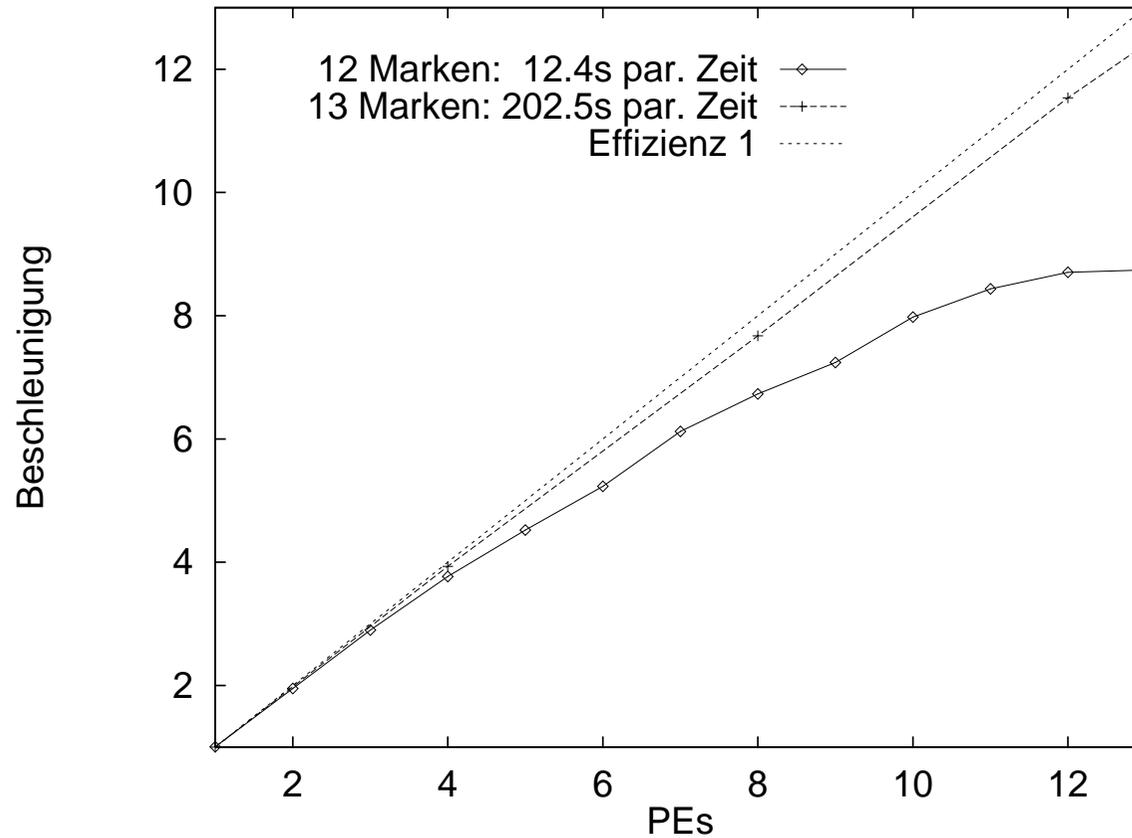
Many Processors

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

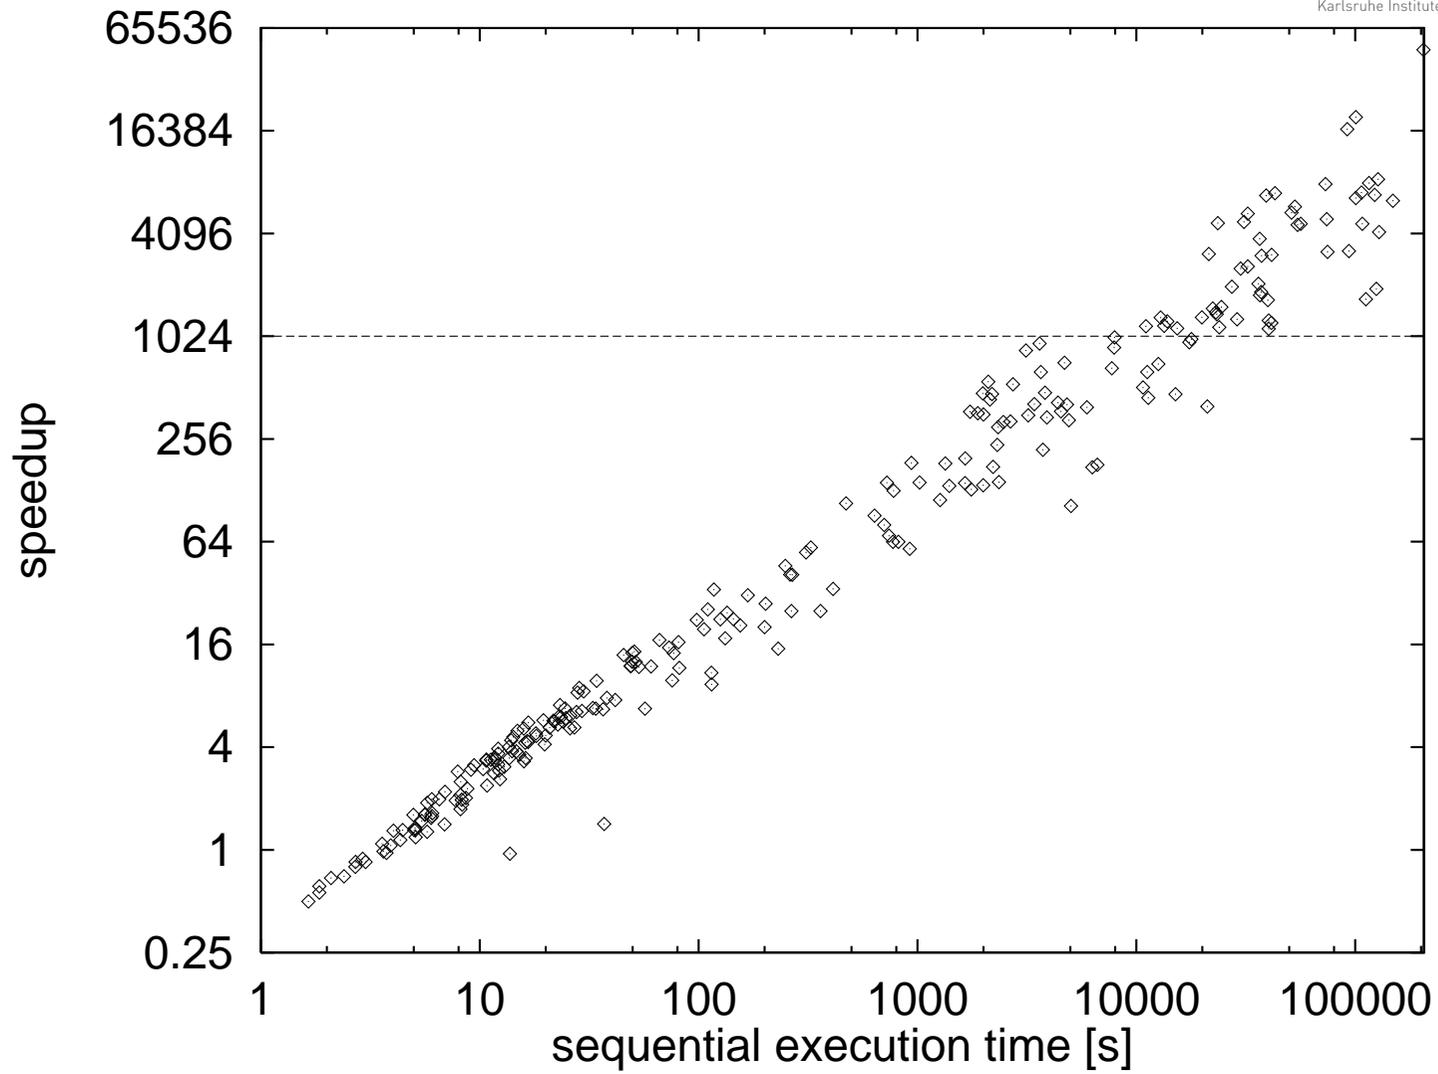
- m items
- maximum knapsack weight M
- item weights w_i
- item profits p_i
- Find $x_i \in \{0, 1\}$ such that
 - $\sum w_i x_i \leq M$
 - $\sum p_i x_i$ is maximized

Best known approach for large m :

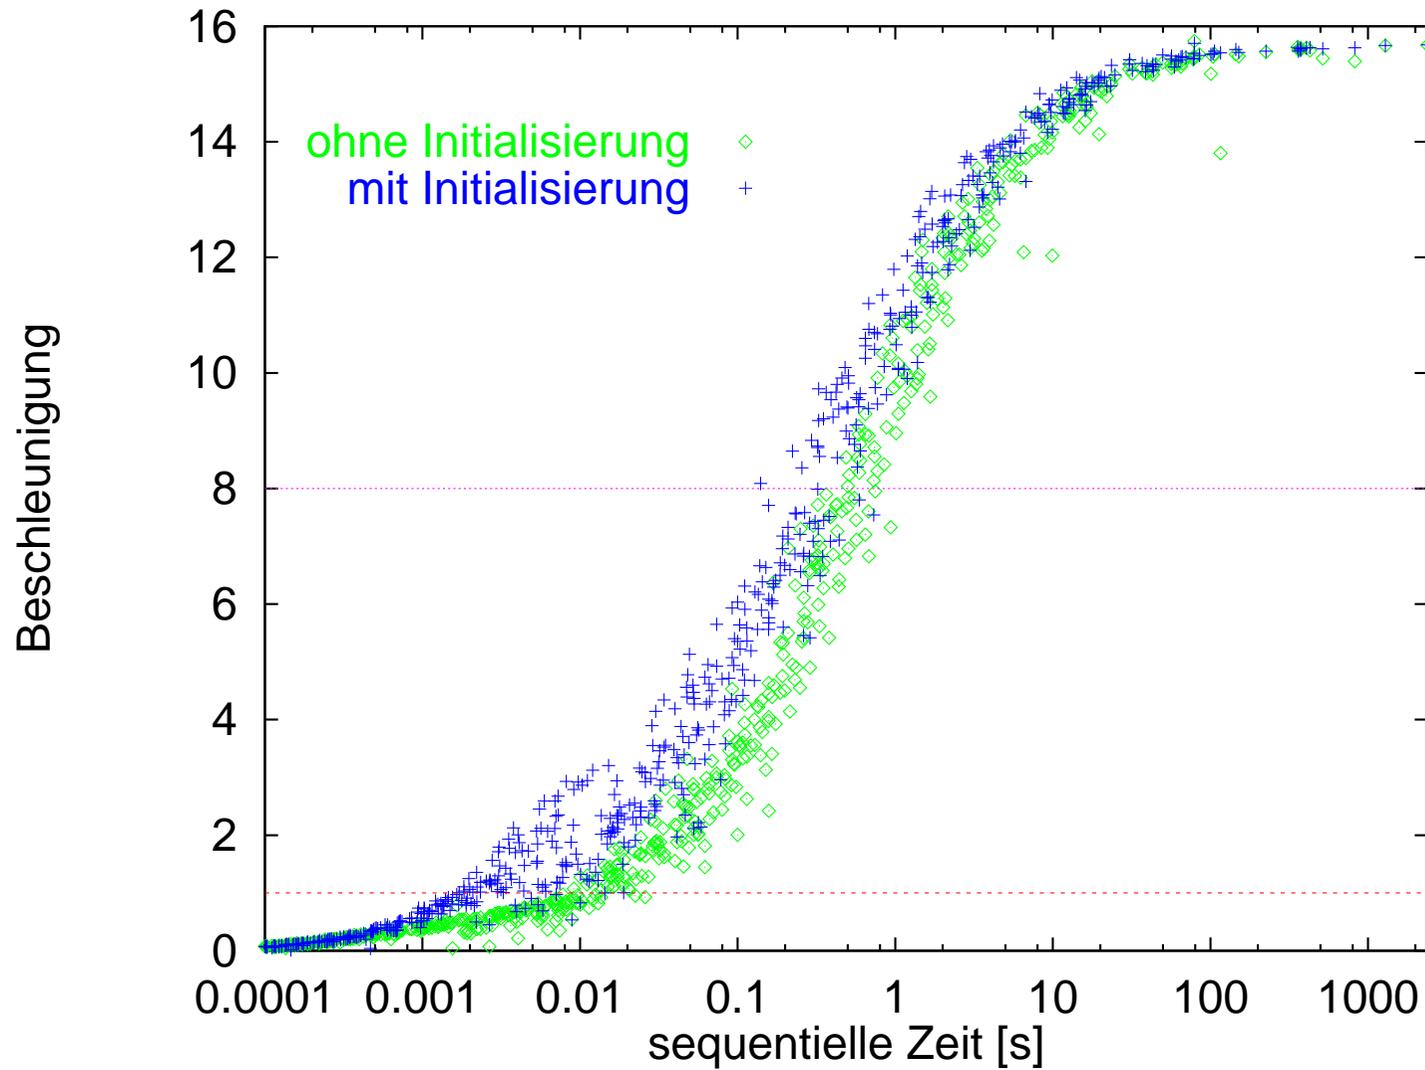
- Depth-first branch-and-bound
- Bounding function based on a the relaxation $x_i \in [0, 1]$. (Can be computed in $\mathcal{O}(\log m)$ steps.)

Superlinear Speedup

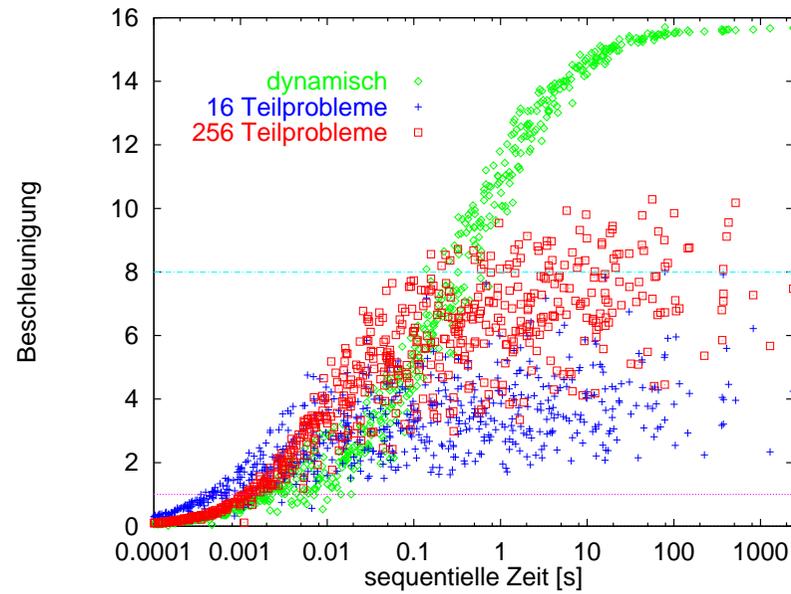
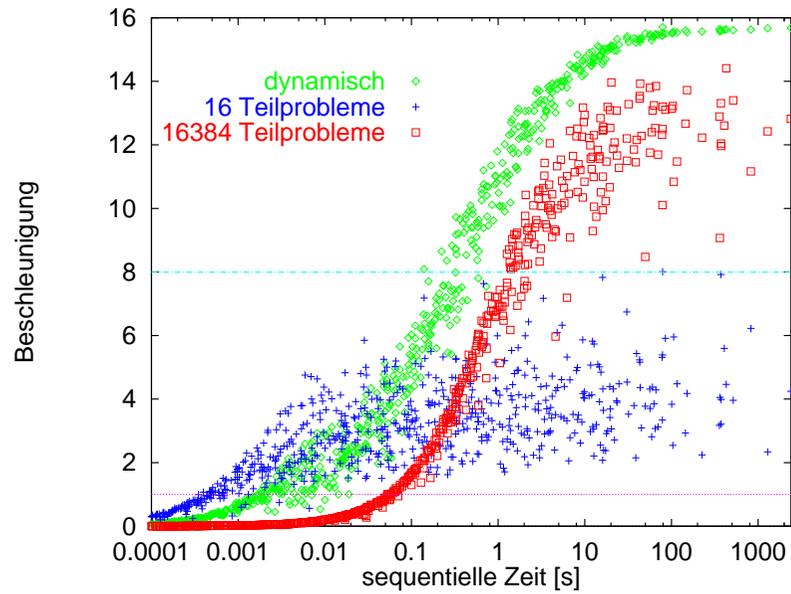
- Parsytec GCel-3/1024 under COSY (PB)
- 1024 processors
- 2000 items
- Splitting on all levels
- 256 random instances at the border between simple and difficult
- overall $1410\times$ faster than seq. computation!



Fast Initialization

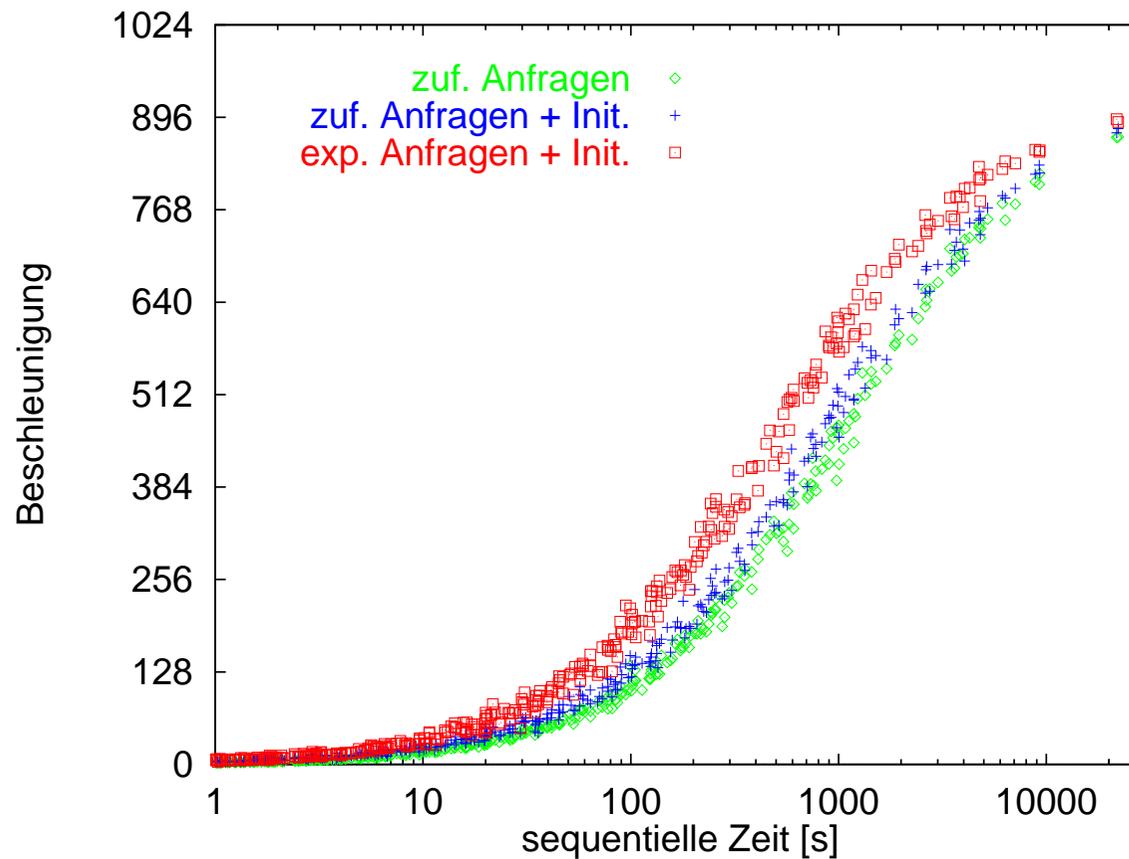


Static vs Dynamic LB



Beyond Global Polling

- Randomized Initialization
- Asynchronously increase polling range (exponentially)



Scalability Comparison Independ. Jobs

\bar{t} = average job size

\hat{t} = maximum job size

T = required total work for parallel execution time $(1 + \epsilon) \frac{\text{total work}}{p}$

Algorithm	$T = \Omega(\dots)$	Remarks
prefix sum	$\frac{p}{\epsilon} (\hat{t} + T_{\text{start}} \log p)$	known task sizes
master-worker	$\frac{p}{\epsilon} \cdot \frac{T_{\text{start}} p}{\epsilon} \cdot \frac{\hat{t}}{\bar{t}}$	bundle size $\sqrt{\frac{m T_{\text{start}}}{\hat{t}}}$
randomized static	$\frac{p}{\epsilon} \cdot \frac{\log p}{\epsilon} \cdot \hat{t}$	randomized
work stealing	$\frac{p}{\epsilon} (\hat{t} + T_{\text{start}} \log p)$	randomized

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

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

`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