

# **Algorithmen II**

**Peter Sanders, Timo Bingmann**

**Übungen:**

**Tobias Heuer, Sebastian Lamm**

Institut für Theoretische Informatik

Web:

[http://algo2.iti.kit.edu/AlgorithmenII\\_WS19.php](http://algo2.iti.kit.edu/AlgorithmenII_WS19.php)

# Organisatorisches

## Vorlesungen:

Mo 09:45–11:15 HS Neue Chemie

Di 15:45–16:30 HS Neue Chemie

## Saalübung:

Di 16:30–17:15 HS Neue Chemie

## Übungsblätter:

14-tägig, jeweils Dienstags, Musterlösung 9 Tage später

1. Blatt: 22.10.2019

# Organisatorisches

## Sprechstunden:

- Peter Sanders, Dienstag 13:45–14:45 Uhr, Raum 217
- Tobias Heuer, nach Absprache, Raum 209
- Sebastian Lamm, nach Absprache, Raum 210

## Ilias Forum: Link auf

`http://algo2.iti.kit.edu/AlgorithmenII\_WS19.php`

**Letzte Vorlesung:** 04. Februar 2020

**Klausur:** Dienstag, 20. März 2020, 11:00 Uhr

# Materialien

Folien

Übungsblätter

Buch:

K. Mehlhorn, P. Sanders

Sequential and Parallel

Algorithms and Data Structures — The Basic Toolbox

Springer 2019. Ca. 45 % der Vorlesung.

Skript: Minimalistischer Aufschrieb der Sachen, die nicht im Buch stehen, mit Verweisen auf Originalliteratur

Sprache: **Deutsch**.

Aber Literatur und ein Teil der Folien auf **Englisch**

## Zum Weiterlesen

- [Dementiev, Dietzfelbinger, Mehlhorn, Sanders]  
Sequential and **Parallel** Algorithm and Data Structures — The Basic Toolbox
- [Mehlhorn, Näher] **Algorithm Engineering, Flows, Geometrie**  
The LEDA Platform of Combinatorial and Geometric Computing.
- [Ahuja, Magnanti, Orlin] Network Flows
- [de Berg, Cheong, van Kreveld, Overmars] **Geometrie**  
Computational Geometry: Algorithms and Applications
- [Gonzalo Navarro] **Succinct Data Structures**  
Compact Data Structures: A Practical Approach
- [R. Niedermeier] Invitation to Fixed-Parameter Algorithms

# Inhaltsübersicht I

- Algorithm Engineering
- Fortgeschrittene Datenstrukturen am Beispiel von Prioritätslisten
  - adressierbar
  - ganzzahlige Schlüssel
  - (Externspeicher)
- Fortgeschrittene Graphenalgorithmen
  - Kürzeste Wege II: negative Kreise, Potentialmethode
  - Starke Zusammenhangskomponenten
  - Maximale Flüsse und Matchings

## Inhaltsübersicht II

- “Bindestrichalgorithmen”
  - Randomisierte Algorithmen
  - Externe Algorithmen
  - Parallele Algorithmen
  - Stringalgorithmen: sorting, indexing, . . .
  - Geometrische Algorithmen
  - Approximationsalgorithmen
  - Fixed-Parameter-Algorithmen
  - Onlinealgorithmen

# Zusammenfassung – Rolle der Algorithmik

- Kerndisziplin der Informatik
- Das Herz jeder nichttrivialen Computeranwendung
- Algorithm Engineering führt zu wohlverstandenen Lösungen für eine Vielzahl von Problemen

# “Machine Learning macht das von selbst?”

- Machine Learning Algorithmen sind auch Algorithmen
- Spezialisiertere Algorithmen finden bei wohlverstandenen Problemen bessere, schnellere und **robustere** Lösungen
- Teile Problem in wohlverstandenen Teil und den Rest
- Machine Learning für Parameter-Tuning?
- Spezialisierte Algorithmen für wohlverstandene Teile, z.B. Feature-Extraktion oder Indexdatenstrukturen?



# 1 Algorithm Engineering

## A detailed definition

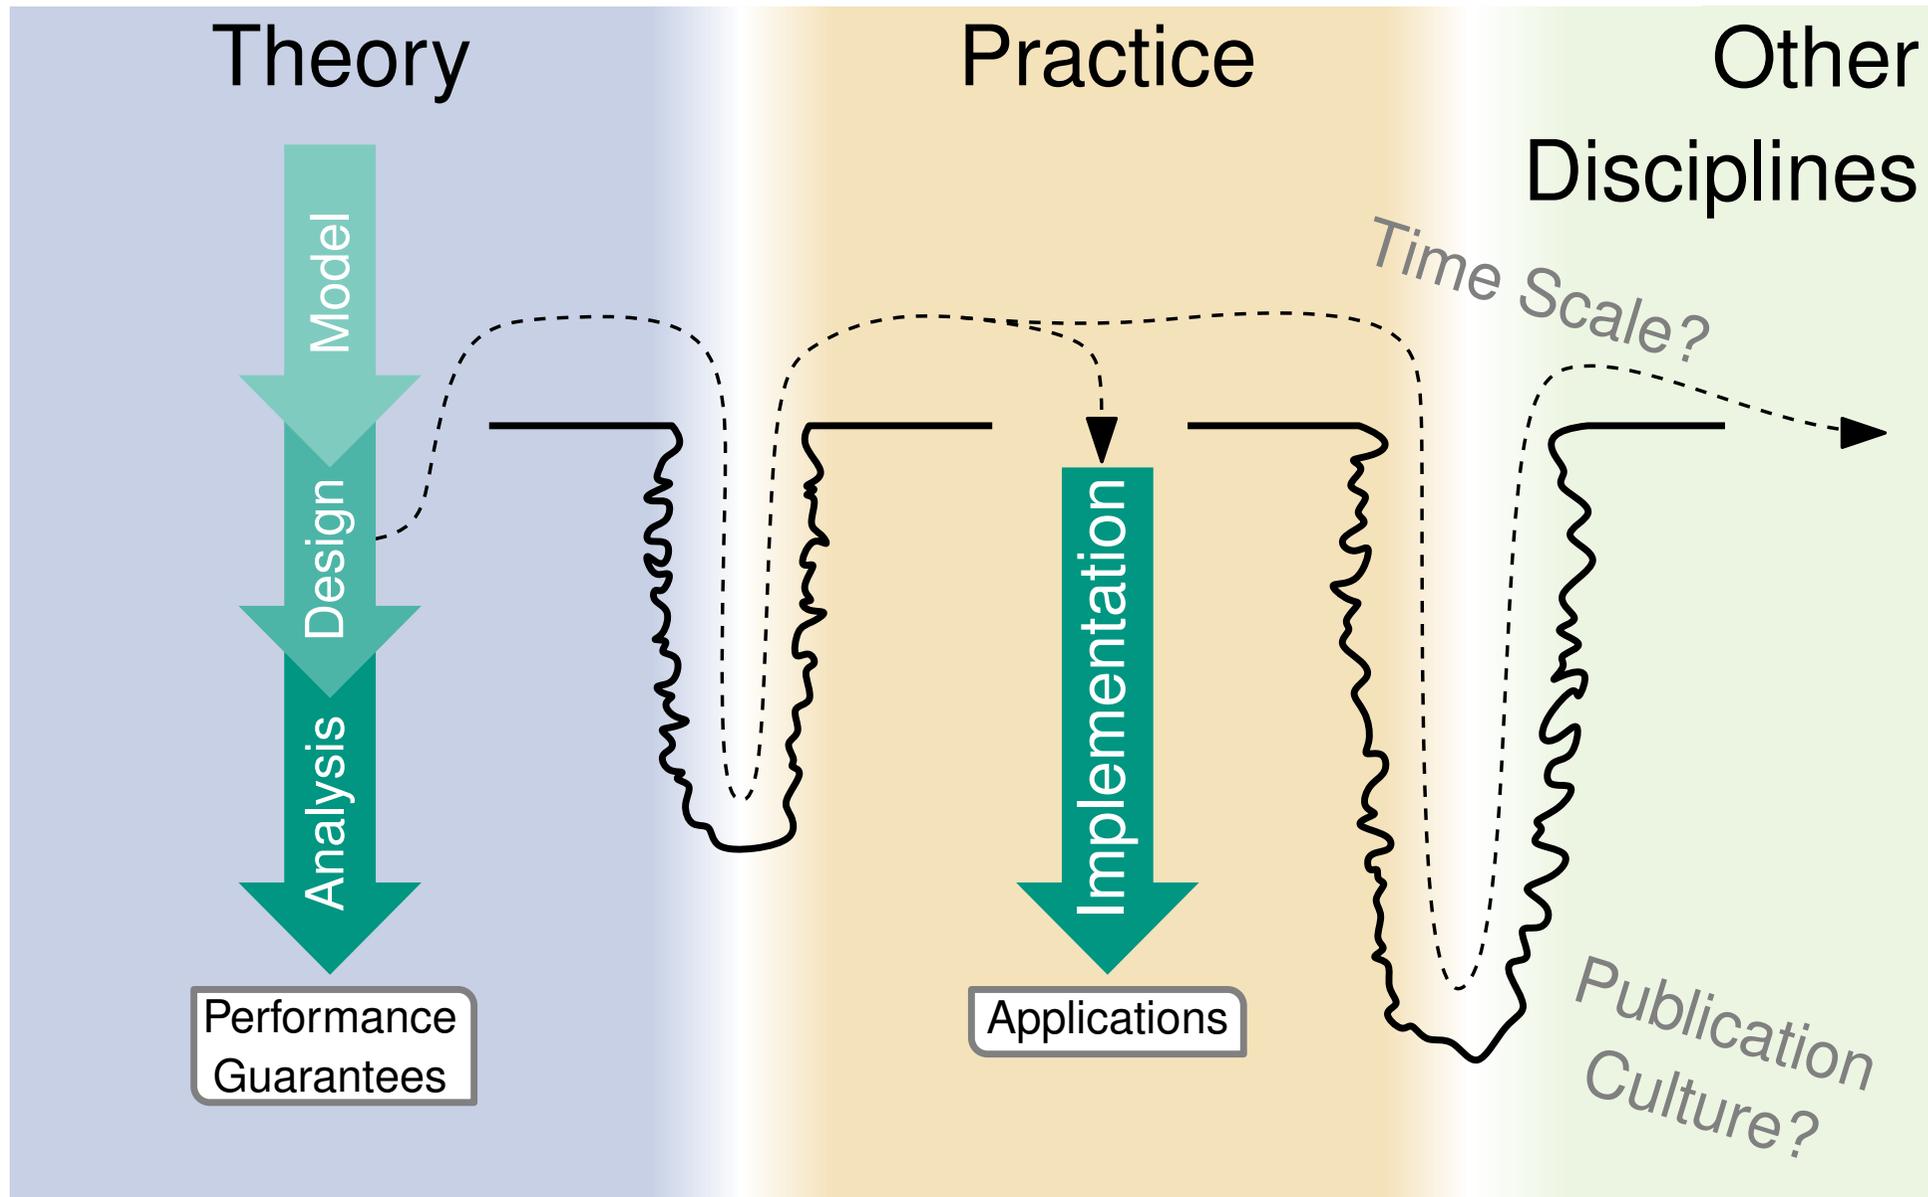
- in general

[with Kurt Mehlhorn, Rolf Möhring, Petra Mutzel, Dorothea Wagner]

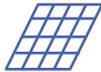
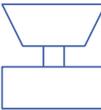
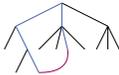
- A few examples, usually sorting

- A little bit on experimental methodology

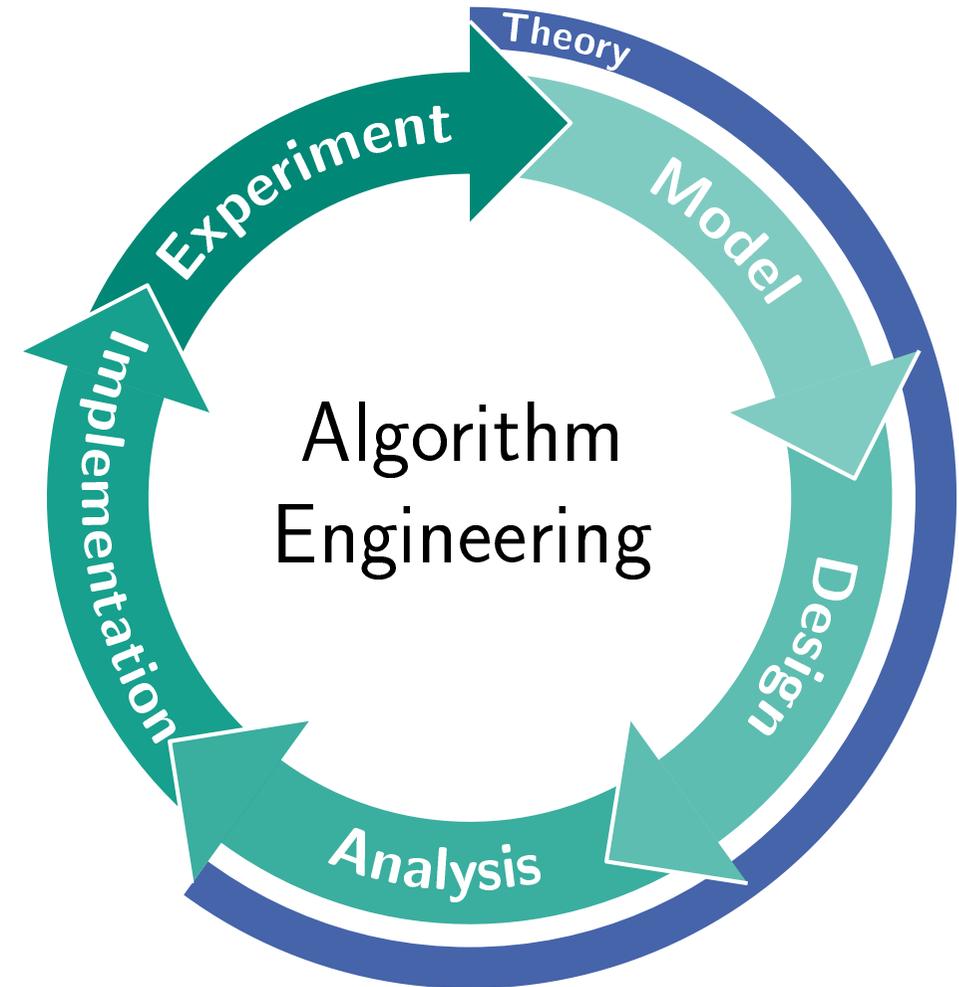
# (Caricatured) Traditional View: Algorithm Theory



# Gaps Between Theory & Practice

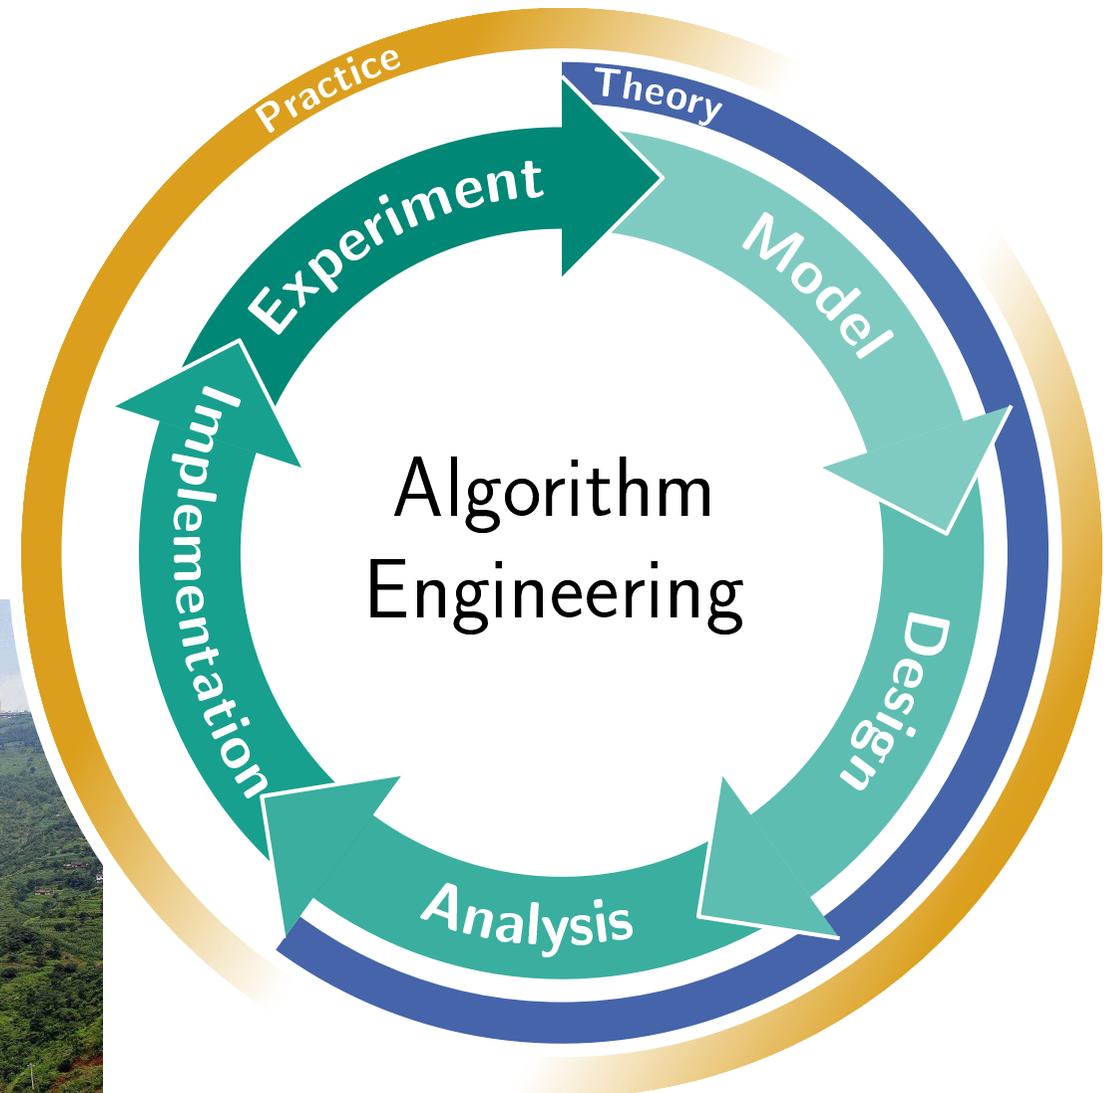
Theory		$\longleftrightarrow$	Practice	
simple		<b>appl. model</b>		complex
simple		<b>machine model</b>		real
complex		<b>algorithms</b>	<code>FOR</code>	simple
advanced		<b>data structures</b>		arrays,...
worst case	<code>max</code>	<b>complexity measure</b>		inputs
asympt.	<code>O(·)</code>	<b>efficiency</b>	<code>42%</code>	constant factors

# Algorithmics as Algorithm Engineering



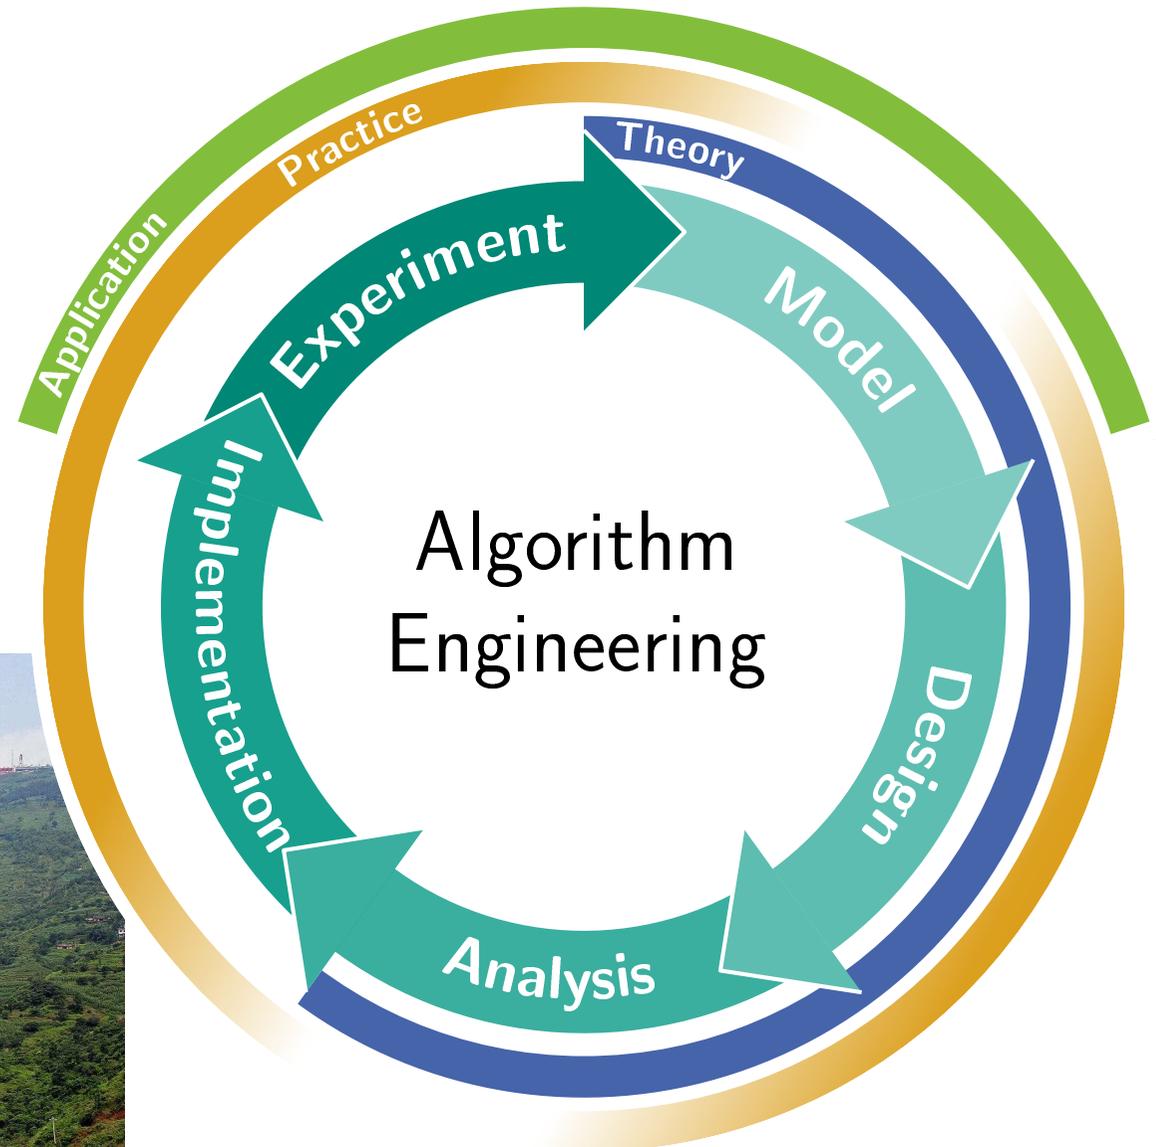
# Algorithmics as Algorithm Engineering

- **bridge gaps** between theory and practice

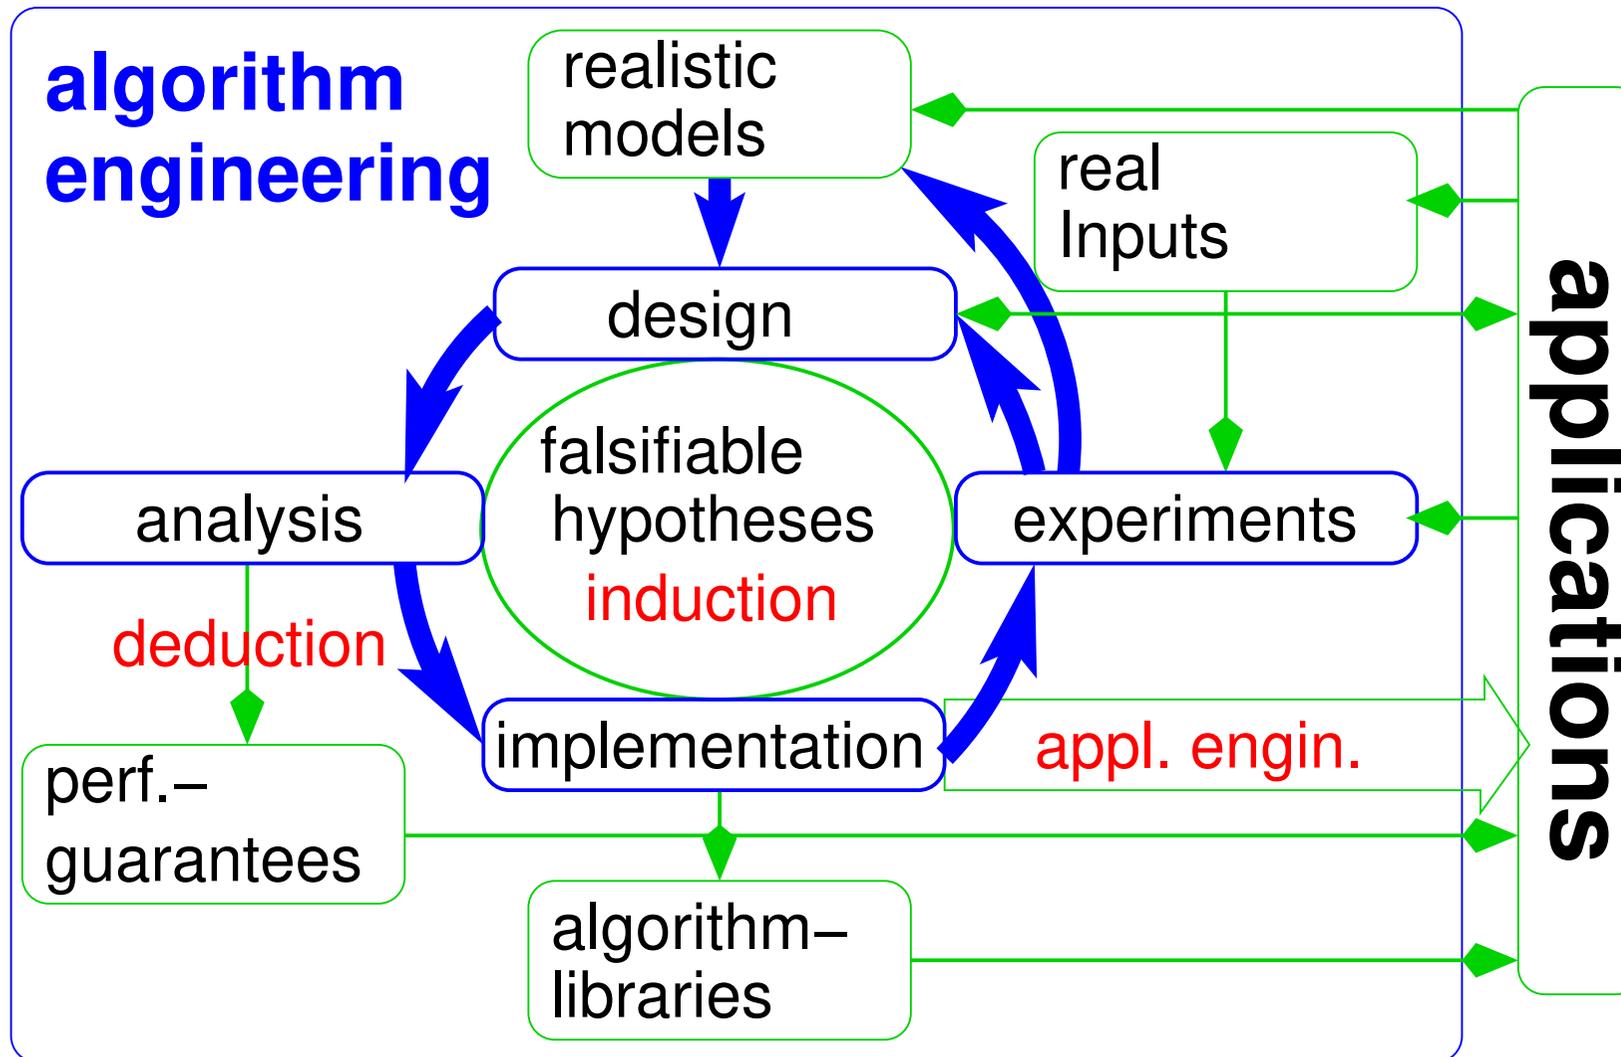


# Algorithmics as Algorithm Engineering

- bridge gaps between theory and practice
- integrated interdisciplinary research



# Algorithmics as Algorithm Engineering



# Bits of History

1843– Algorithms in theory and practice

1950s, 1960s Still infancy

1970s, 1980s Paper and pencil algorithm theory.

Exceptions exist, e.g., [D. Johnson], [J. Bentley]

1986 Term used by [T. Beth],

lecture “**Algorithmentechnik**” in Karlsruhe.

1988– Library of Efficient Data Types and Algorithms  
(LEDA) [K. Mehlhorn]

1997– **Workshop on Algorithm Engineering**

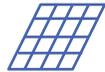
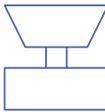
↪ ESA applied track [G. Italiano]

1997 Term used in US policy paper [Aho, Johnson, Karp, et. al]

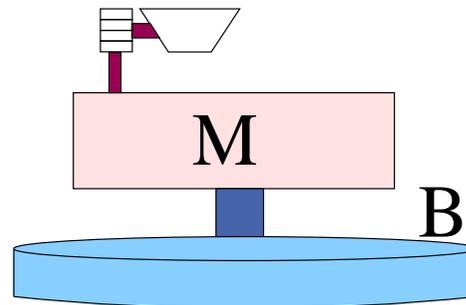
1998 **Alex** workshop in Italy ↪ **ALENEX**



# Realistic Models

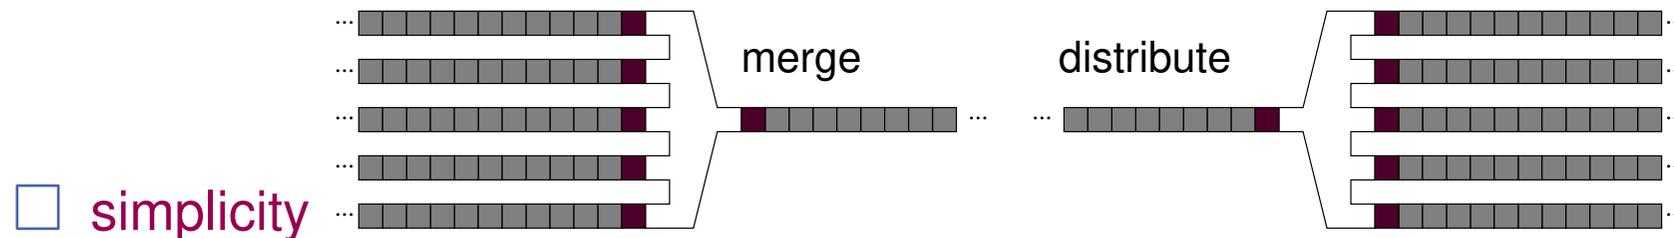
Theory	$\longleftrightarrow$	Practice
simple 	<b>appl. model</b>	 complex
simple 	<b>machine model</b>	 real

- Careful refinements
- Try to preserve (partial) analyzability / simple results



# Design

of algorithms that work well in **practice**



- simplicity**
- reuse**
- constant** factors
- exploit **easy** instances

# Analysis

- Constant factors** matter  
Beispiel: quicksort
- Beyond worst case** analysis
- Practical algorithms** might be difficult to analyze  
(randomization, meta heuristics, . . .)

# Implementation

sanity check for algorithms !

## Challenges

Semantic gaps:

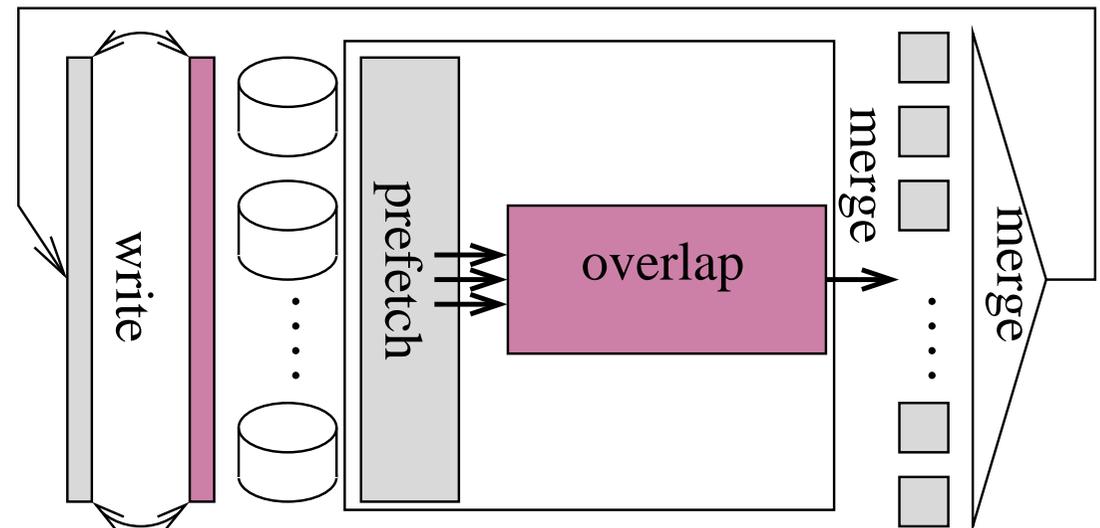
Abstract algorithm

↔

C++...

↔

hardware



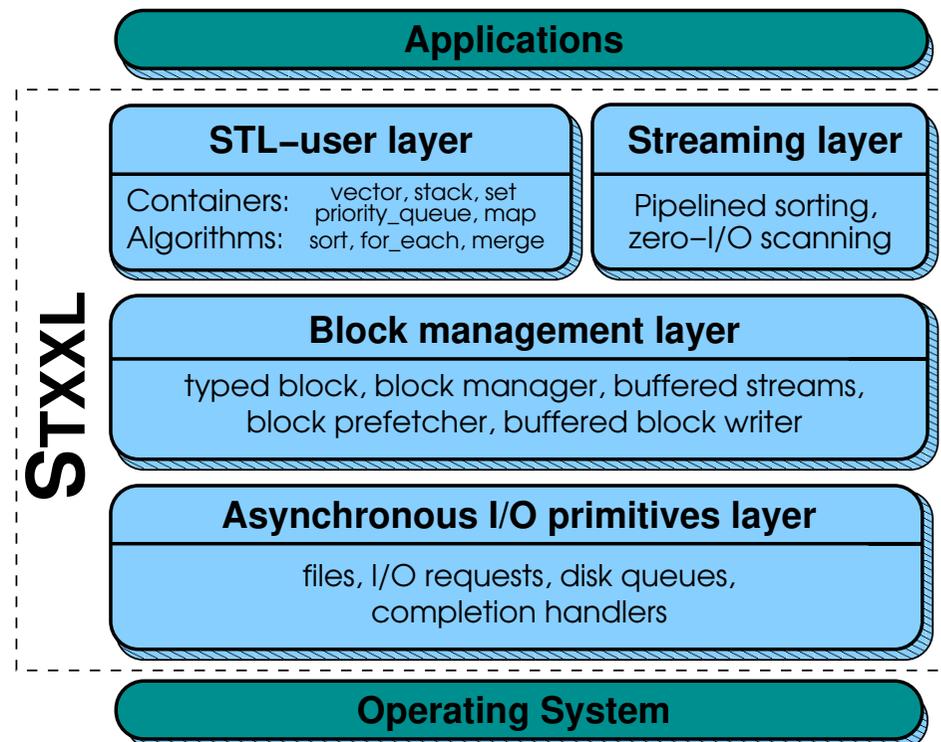
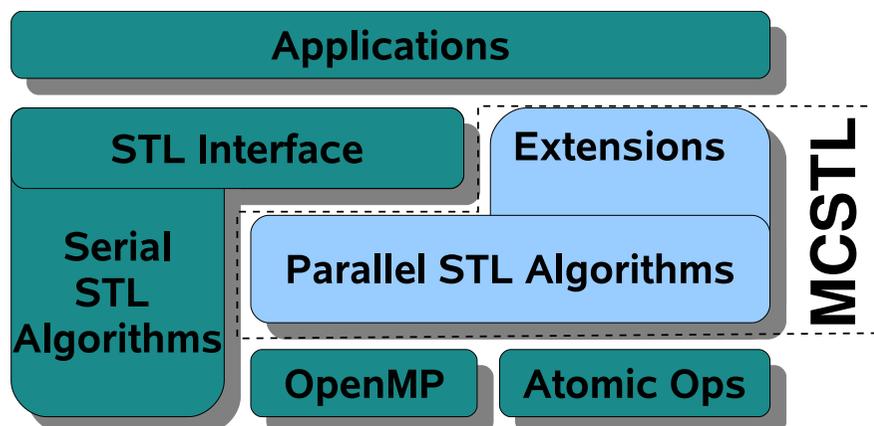
# Experiments

- sometimes a good **surrogate** for analysis
- too much** rather than too little **output data**
- reproducibility** (10 years!)
- software engineering**

**Stay tuned.**

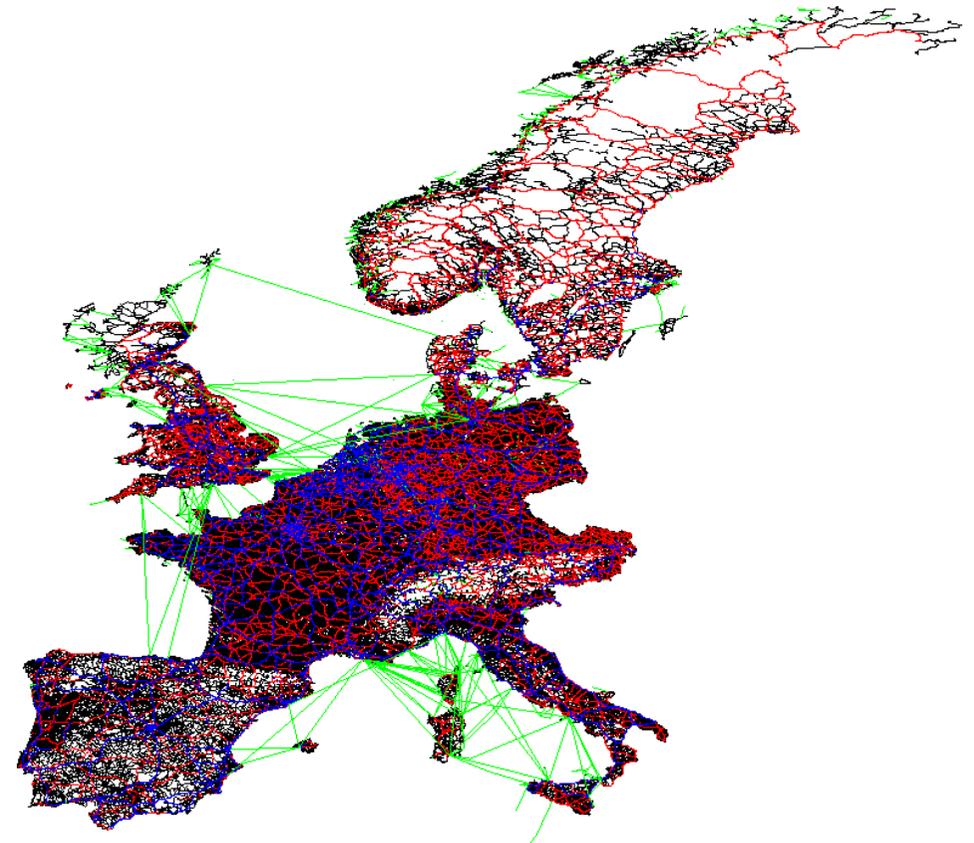
# Algorithm Libraries — Challenges

- software engineering
- standardization, e.g. java.util, C++ STL and BOOST
- performance ↔ generality ↔ simplicity
- applications are a priori unknown
- result checking, verification



# Problem Instances

Benchmark instances are essential for development of practical algorithms





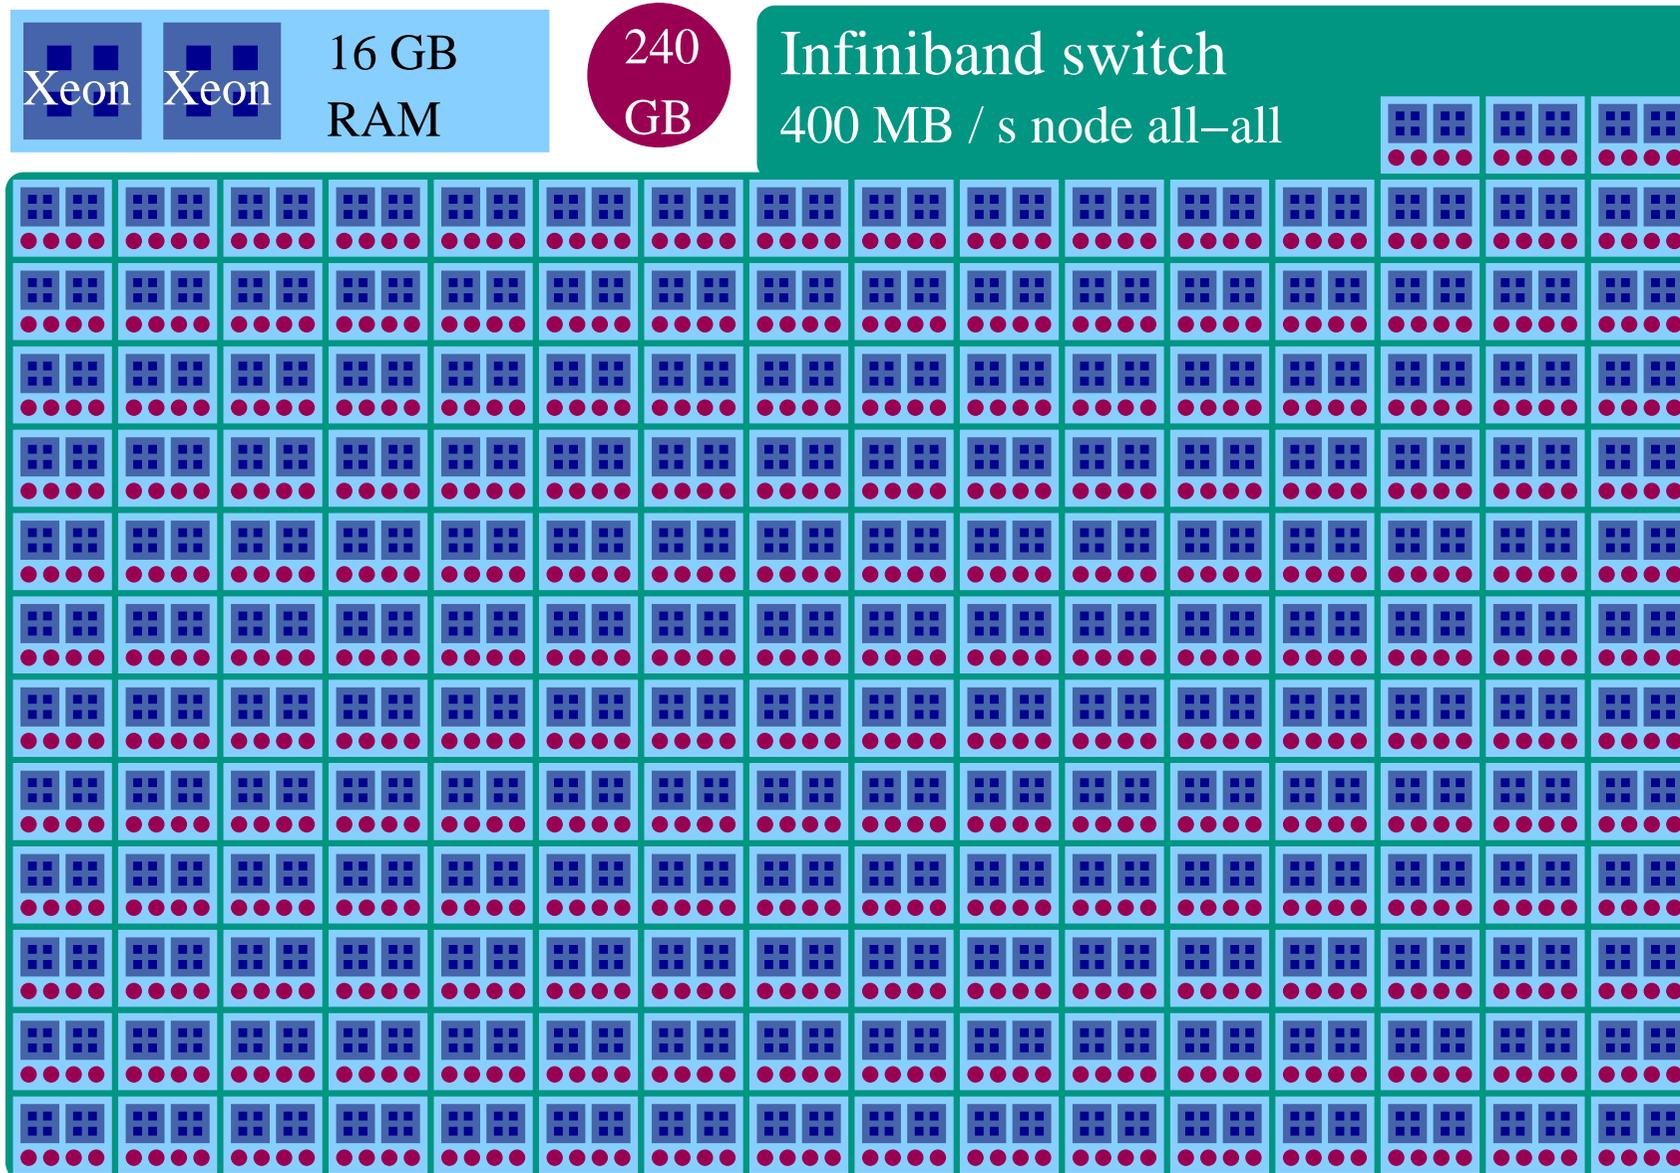
## Example: Sorting Benchmark (Indy)

100 byte records, 10 byte random keys, with file I/O

Category	data volume	performance	improvement
GraySort	100 000 GB	564 GB / min	17×
MinuteSort	955 GB	955 GB / min	> 10×
JouleSort	100 000 GB	3 400 Recs/Joule	???
JouleSort	1 000 GB	17 500 Recs/Joule	5.1×
JouleSort	100 GB	39 800 Recs/Joule	3.4×
JouleSort	10 GB	43 500 Recs/Joule	5.7×

Also: PennySort

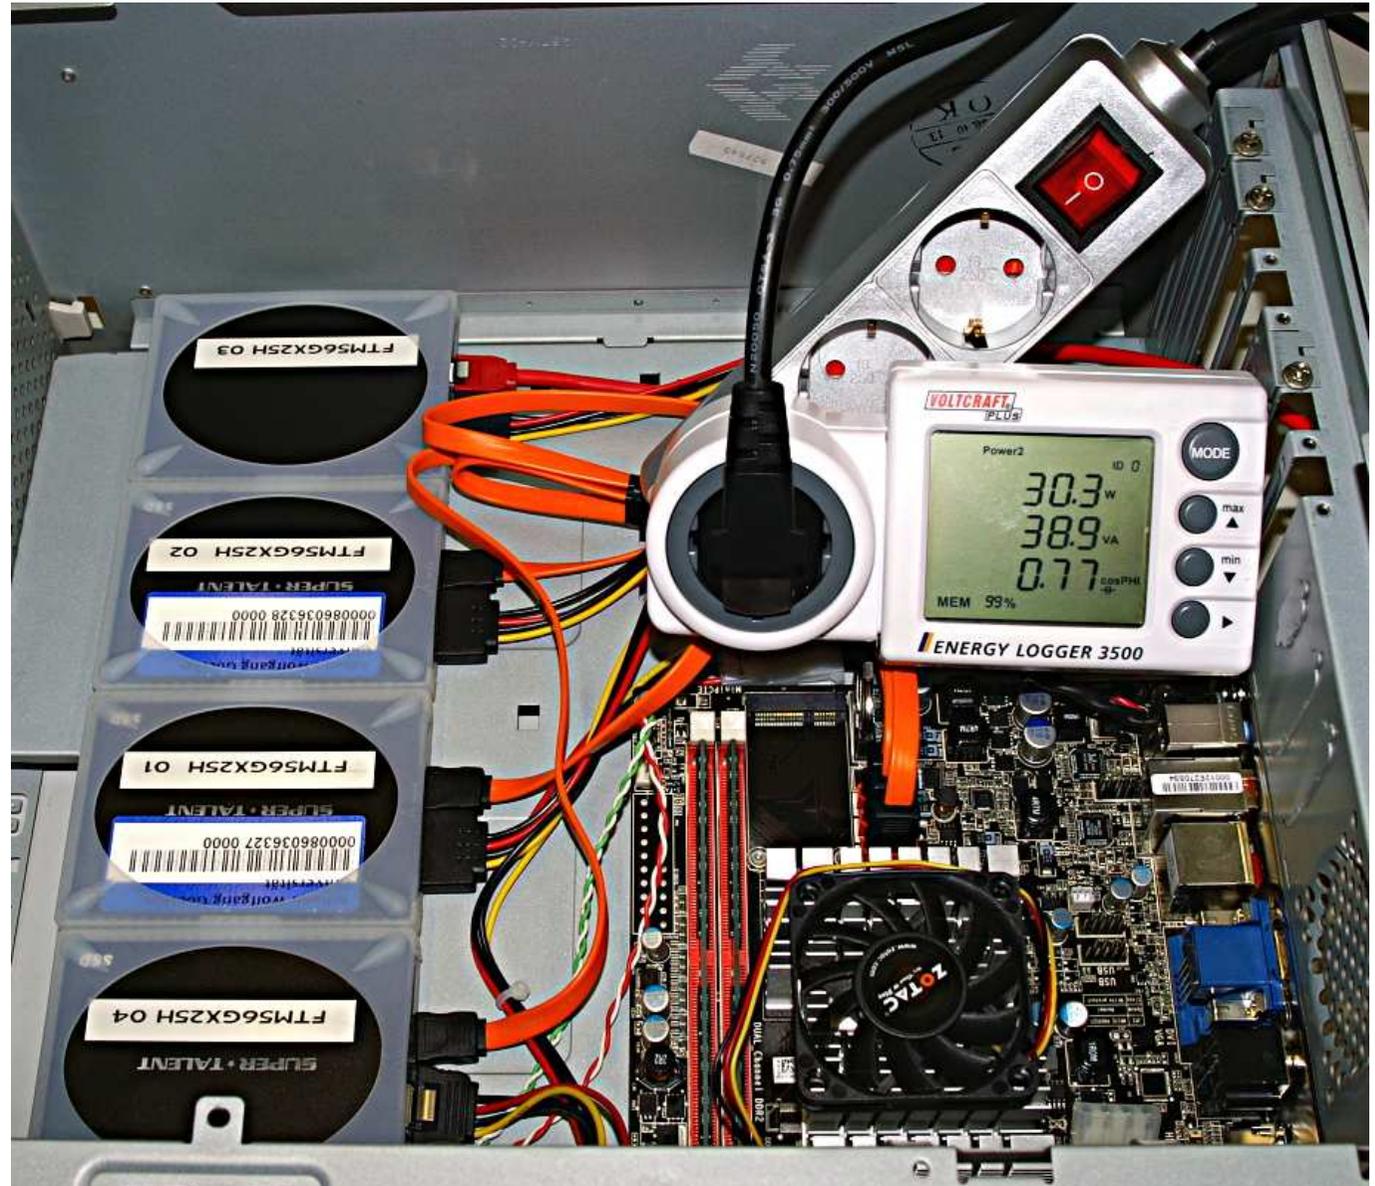
# GraySort: *inplace* multiway mergesort, *exact* splitting



# JouleSort

- Intel Atom N330
- 4 GB RAM
- 4 × 256 GB  
SSD (SuperTalent)

Algorithm similar to  
GraySort



# Applications that “Change the World”

Algorithmics has the potential to SHAPE applications  
(not just the other way round)

[G. Myers]

**Bioinformatics:** sequencing, proteomics, phylogenetic trees,...



**Information Retrieval:** Searching, ranking,...

**Traffic Planning:** navigation, flow optimization,  
adaptive toll, disruption management

**Geographic Information Systems:** agriculture, environmental  
protection, disaster management, tourism,...

**Communication Networks:** mobile, P2P, cloud, selfish users,...

## Conclusion:

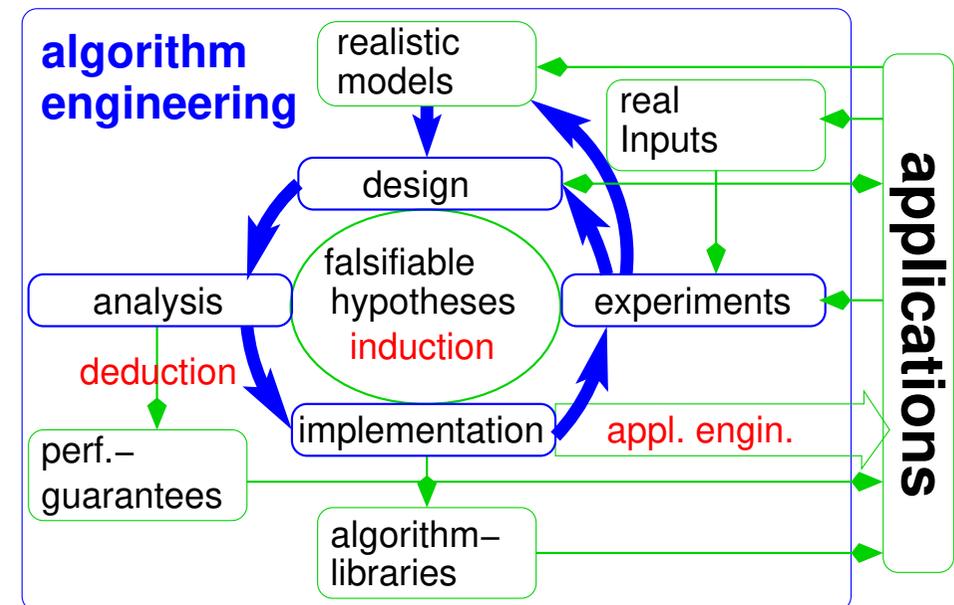
# Algorithm Engineering $\leftrightarrow$ Algorithm Theory

- algorithm engineering is a wider view on algorithmics  
(but no revolution. None of the ingredients is really new)
- rich methodology
- better coupling to applications
- experimental algorithmics  $\ll$  algorithm engineering
- algorithm theory  $\subset$  algorithm engineering
- sometimes different theoretical questions
- algorithm theory may still yield the strongest, deepest and most persistent results within algorithm engineering

# More On Experimental Methodology

## Scientific Method:

- Experiment need a possible outcome that **falsifies** a hypothesis
- Reproducible
  - keep data/code for at least 10 years
  - + documentation (aka laboratory journal (Laborbuch))
- clear and detailed description in papers / TRs
- share instances and code



# Quality Criteria

- Beat the state of the art, globally – (not your own toy codes or the toy codes used in your community!)
- Clearly** demonstrate this !
  - both codes use same data ideally from accepted benchmarks (not just your favorite data!)
  - comparable machines or fair (conservative) scaling
  - Avoid uncomparabilities like:
    - “Yeah we have worse quality but are twice as fast”
  - real world data wherever possible
  - as much **different**, **fresh** inputs as possible
  - its fine if you are better just on some (important) inputs

# Not Here but Important

- describing the setup (machine, compiler, OS, instances, repetitions, . . . )
- finding sources of measurement errors
- reducing measurement errors (averaging, median, unloaded machine. . . )
- measurements in the **creative** phase of experimental algorithmics.

# The Starting Point

- (Several) Algorithm(s)
- A few quantities to be measured: time, space, solution quality, comparisons, cache faults, . . . There may also be **measurement errors**.
- An unlimited number of potential inputs.  $\rightsquigarrow$  condense to a few characteristic ones (size,  $|V|$ ,  $|E|$ , . . . or problem instances from applications)

Usually there is not a lack but an **abundance** of data  $\neq$  many other sciences

# The Process

Waterfall model?

1. Design
2. Measurement
3. Interpretation

Perhaps the paper should at least look like that.

# The Process

- Eventually stop asking questions (Advisors/Referees listen !)
- build measurement tools
- automate (re)measurements
- Choice of Experiments driven by risk and opportunity
- Distinguish mode

**explorative:** many different parameter settings, interactive, short turnaround times

**consolidating:** many large instances, standardized measurement conditions, batch mode, many machines

# Of Risks and Opportunities

Example: Hypothesis = my algorithm is the best

**big risk:** untried main competitor

**small risk:** tuning of a subroutine that takes 20 % of the time.

**big opportunity:** use algorithm for a new application

~> new input instances

## 2 Fortgeschrittene Datenstrukturen

Hier am Beispiel von Prioritätslisten.

Weitere Beispiele:

- Monotone ganzzahlige Prioritätslisten      Kapitel kürzeste Wege
- perfektes **Hashing**      Kapitel rand. Alg.
- Suchbäume** mit fortgeschrittenen Operationen      siehe Buch
- Externe Prioritätslisten      Kapitel externe Algorithmen
- Geometrische** Datenstrukturen      Kapitel geom. Algorithmen

## 2.1 Adressierbare Prioritätslisten

**Procedure** build( $\{e_1, \dots, e_n\}$ )  $M := \{e_1, \dots, e_n\}$

**Function** size **return**  $|M|$

**Procedure** insert( $e$ )  $M := M \cup \{e\}$

**Function** min **return**  $\min M$

**Function** deleteMin  $e := \min M$ ;  $M := M \setminus \{e\}$ ; **return**  $e$

**Function** remove( $h : \text{Handle}$ )  $e := h$ ;  $M := M \setminus \{e\}$ ; **return**  $e$

**Procedure** decreaseKey( $h : \text{Handle}, k : \text{Key}$ ) **assert**  $\text{key}(h) \geq k$ ;  $\text{key}(h) := k$

**Procedure** merge( $M'$ )  $M := M \cup M'$

# Adressierbare Prioritätslisten: Anwendungen

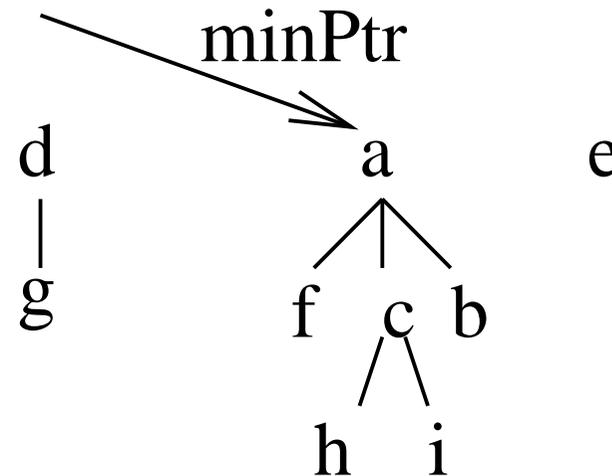
- Dijkstras Algorithmus für **kürzeste Wege**
- Jarník-Prim-Algorithmus für **minimale Spannbäume**
- Bei uns: Hierarchiekonstruktion für **Routenplanung**
- Bei uns: Graphpartitionierung
- Bei uns: disk scheduling

Allgemein:

**Greedy-Algorithmen**, bei denen sich Prioritäten (begrenzt) ändern.

# Grundlegende Datenstruktur

Ein **Wald heap-geordneter** Bäume

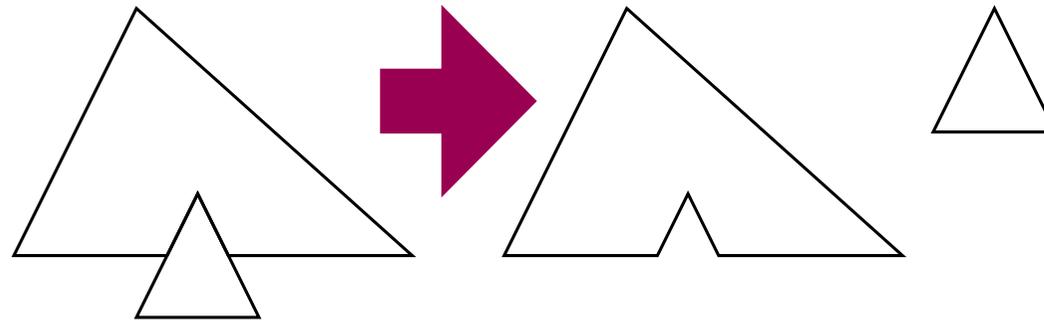


Verallgemeinerung gegenüber binary heap:

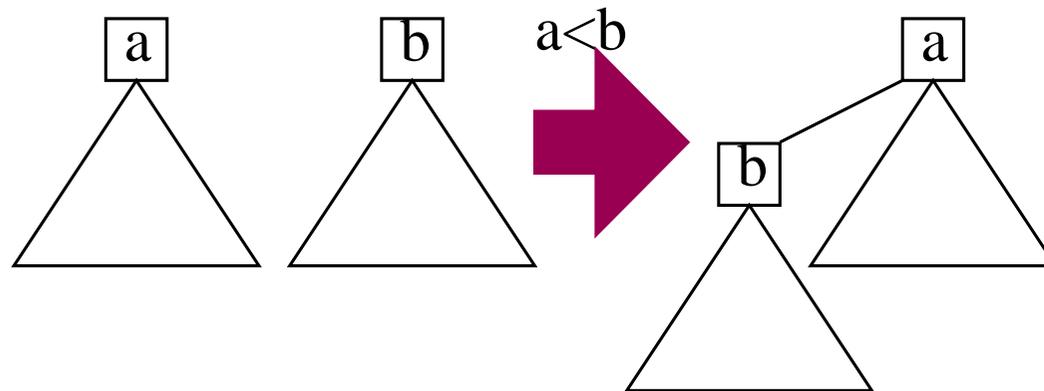
- Baum  $\rightarrow$  Wald
- binär  $\rightarrow$  beliebige Knotengrade

# Wälder Bearbeiten

Cut:



Link:



$\text{union}(a, b): \text{link}(\min(a, b), \max(a, b))$

# Pairing Heaps (Paarungs-Haufen??)

[Fredman Sedgewick Sleator Tarjan 1986]

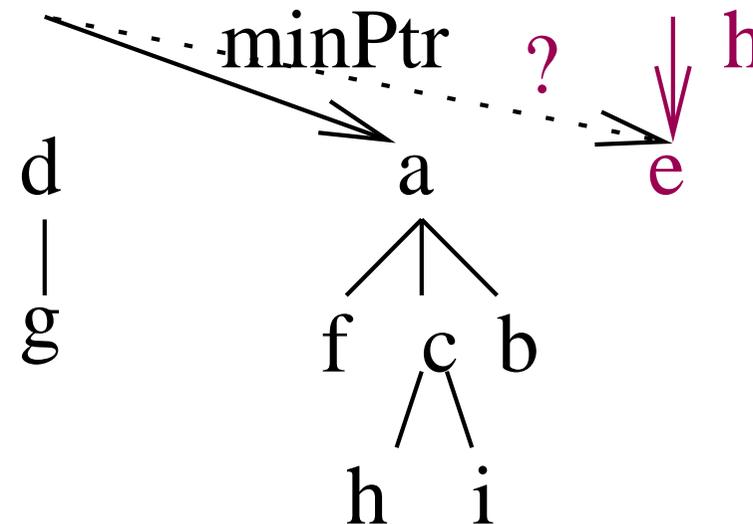
**Procedure** insertItem( $h$  : Handle)

newTree( $h$ )

**Procedure** newTree( $h$  : Handle)

forest := forest  $\cup$  { $h$ }

**if**  $*h < \min$  **then** minPtr :=  $h$



**Vorsicht:** sehr einfache Variante aus 1. engl. Auflage.

dt. Ausgabe, 2. Auflage weichen ab

# Pairing Heaps

**Procedure** decreaseKey( $h$  : Handle,  $k$  : Key)

key( $h$ ) :=  $k$

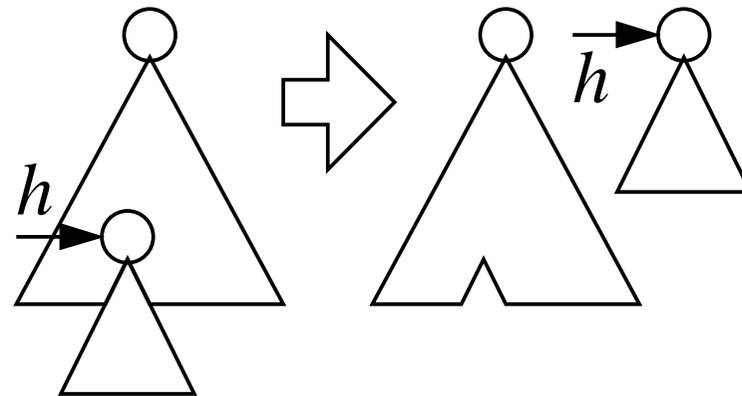
**if**  $h$  is not a root **then** cut( $h$ )

**else** update minPtr

**Procedure** cut( $h$  : Handle)

remove the subtree rooted at  $h$

newTree( $h$ )



# Pairing Heaps

**Function** deleteMin : Handle

$m := \text{minPtr}$

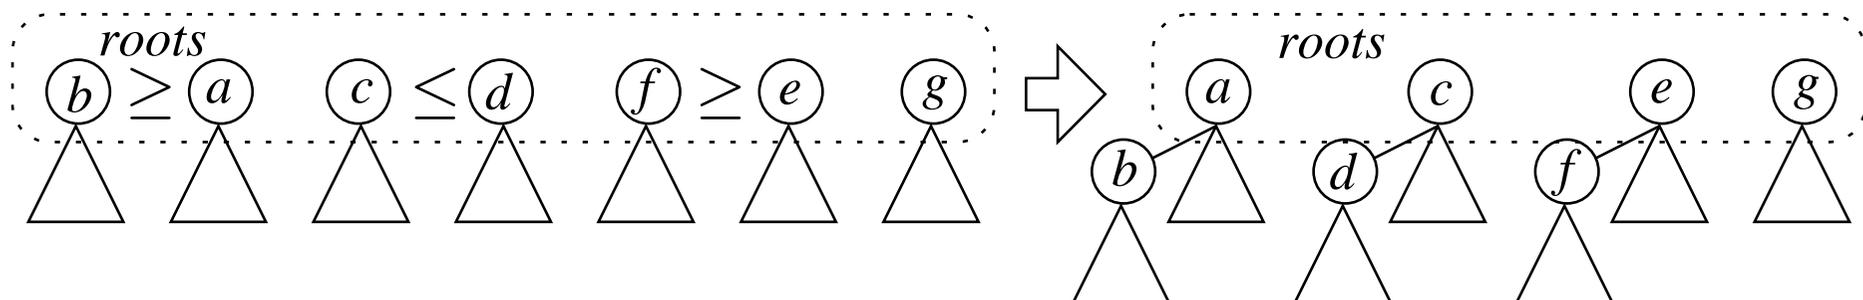
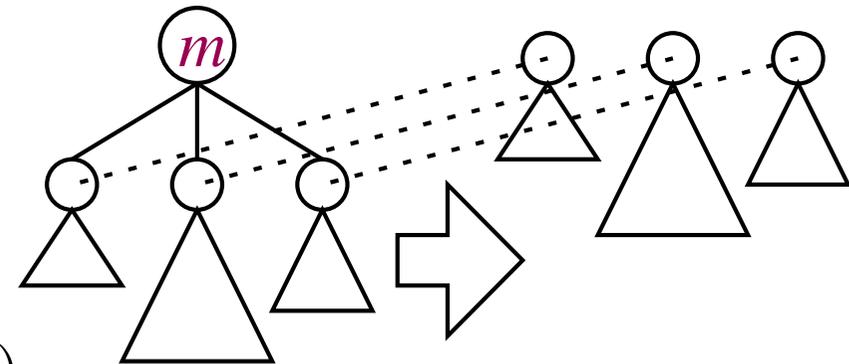
forest := forest  $\setminus \{m\}$

**foreach** child  $h$  of  $m$  **do** newTree( $h$ )

perform **pair-wise union** operations on the roots in forest

update minPtr

**return**  $m$



# Pairing Heaps

**Procedure** merge( $o$  : AdressablePQ)

**if**  $*\text{minPtr} > *(o.\text{minPtr})$  **then**  $\text{minPtr} := o.\text{minPtr}$

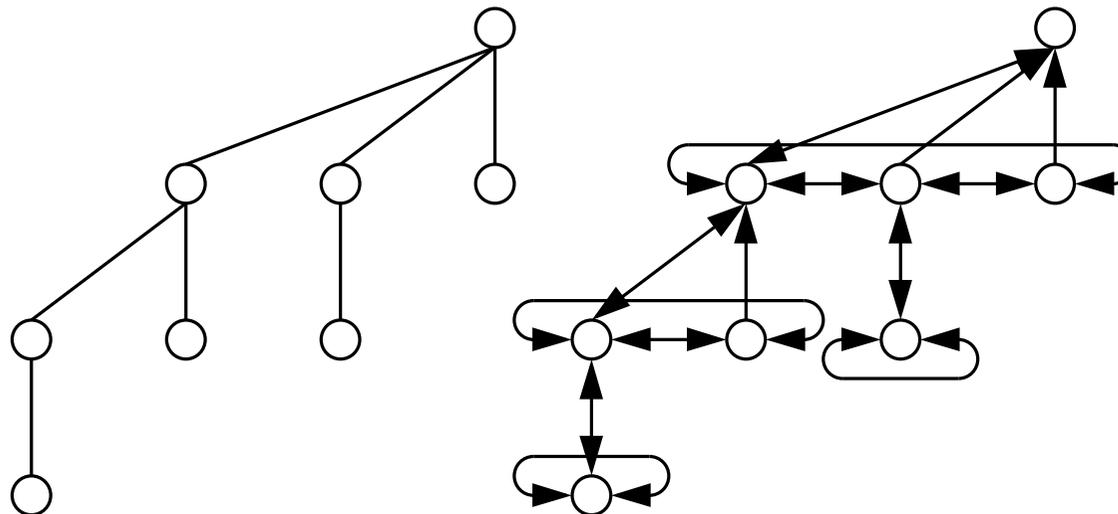
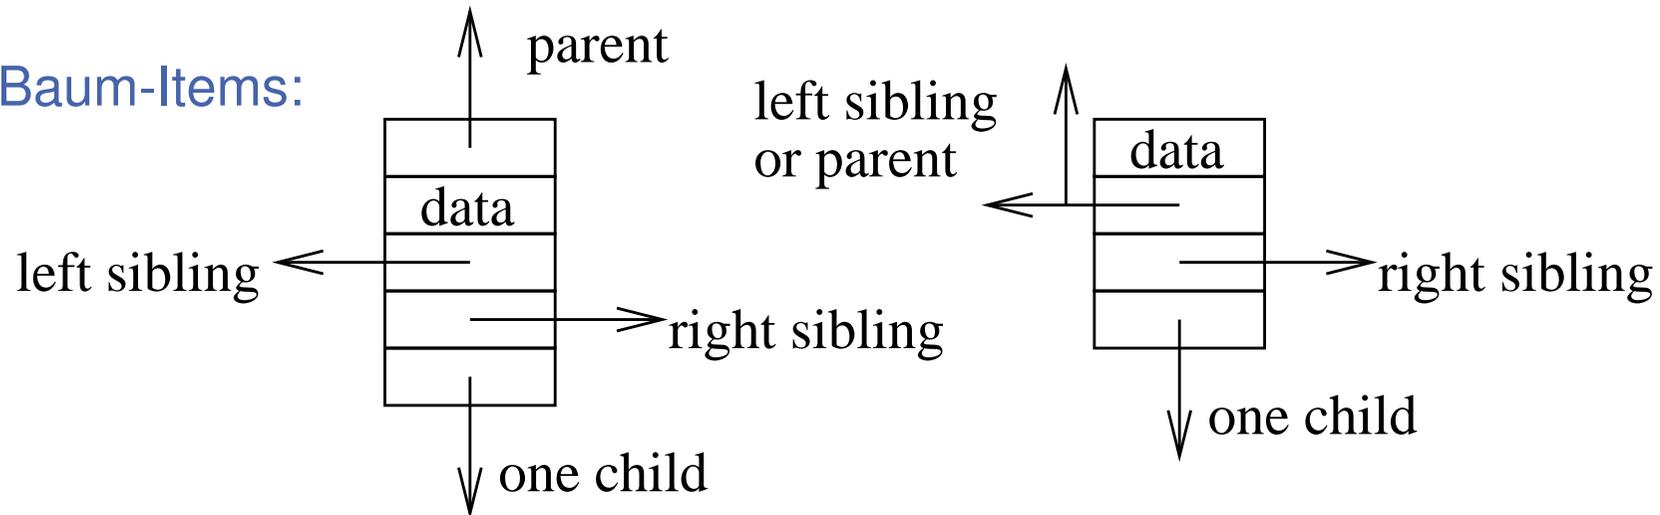
$\text{forest} := \text{forest} \cup o.\text{forest}$

$o.\text{forest} := \emptyset$

# Pairing Heaps – Repräsentation

Wurzeln: Doppelt verkettete Liste

Baum-Items:



## Pairing Heaps – Analyse

insert, merge:  $O(1)$

deleteMin, remove:  $O(\log n)$  amortisiert

decreaseKey: **unklar!**  $O(\log \log n) \leq T \leq O(\log n)$  amortisiert.

In der Praxis sehr schnell.

Beweise: nicht hier.

## Fibonacci Heaps [Fredman Tarjan 1987]

Rang: Anzahl (direkter) Kinder speichern

Vereinigung nach Rang: Union nur für gleichrangige Wurzeln

Markiere Knoten, die ein Kind verloren haben

Kaskadierende Schnitte: Schneide markierte Knoten  
(die also 2 Kinder verloren haben)

**Satz:** Amortisierte Komplexität  $O(\log n)$  für deleteMin, remove und

$O(1)$  für alle anderen Operationen

(d.h.  $Gesamtzeit = O(o + d \log n)$  falls

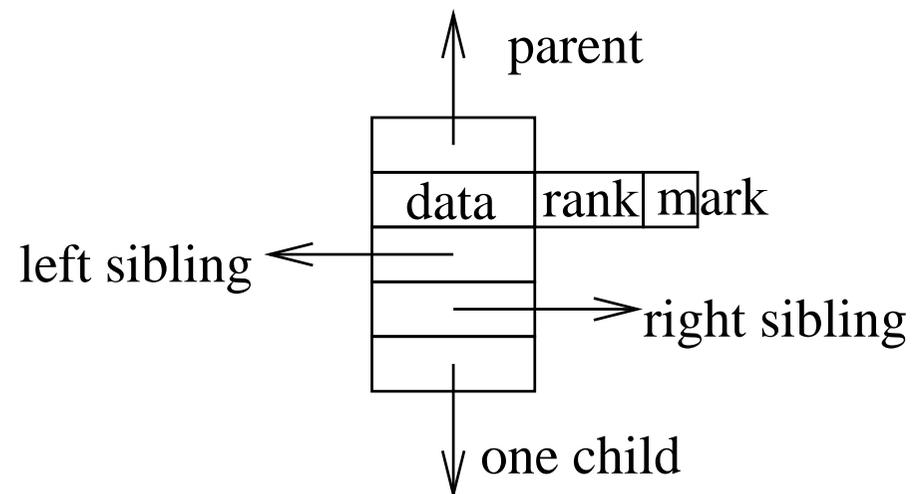
$d = \#deleteMin$ ,  $o = \#otherOps$ ,  $n = \max |M|$ )

# Repräsentation

Wurzeln: Doppelt verkettete Liste

(und ein temporäres Feld für deleteMin)

Baum-Items:



**insert, merge:** wie gehabt. Zeit  $O(1)$

## deleteMin mit Union-by-Rank

**Function** deleteMin : Handle

$m := \text{minPtr}$

$\text{forest} := \text{forest} \setminus \{m\}$

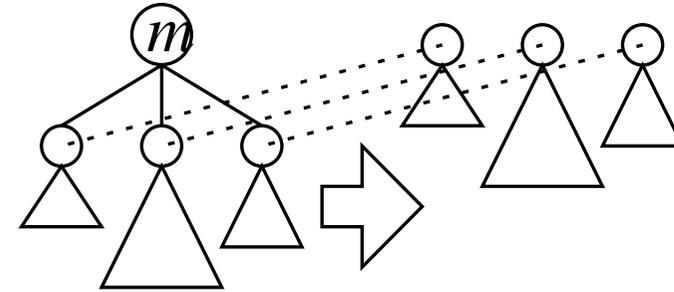
**foreach** child  $h$  of  $m$  **do** newTree( $h$ )

**while**  $\exists a, b \in \text{forest} : \text{rank}(a) = \text{rank}(b)$  **do**

    union( $a, b$ )                      // increments rank of surviving root

update minPtr

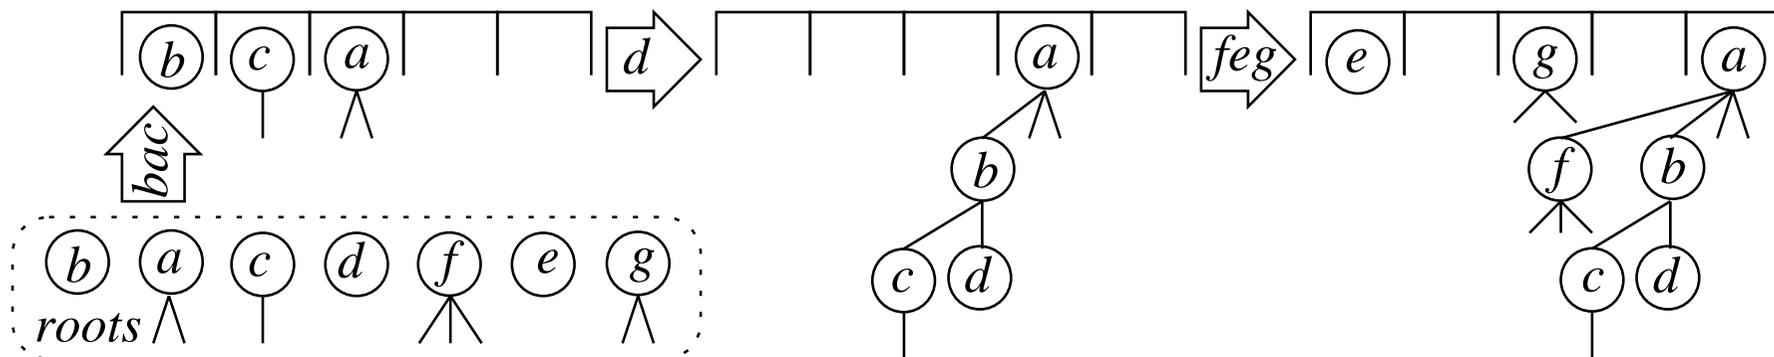
**return**  $m$



# Schnelles Union-by-Rank

Durch rank adressiertes Feld.

Solange link durchführen bis freier Eintrag gefunden.



Analyse: Zeit  $O(\#\text{unions} + |\text{forest}|)$

## Amortisierte Analyse von deleteMin

$$\text{maxRank} := \max_{a \in \text{forest}} \text{rank}(a) \text{ (nachher)}$$

Lemma:  $T_{\text{deleteMin}} = O(\text{maxRank})$

Beweis: Kontomethode. Ein Token pro Wurzel

$$\text{rank}(\text{minPtr}) \leq \text{maxRank}$$

$\rightsquigarrow$  Kosten  $O(\text{maxRank})$  für newTrees und neue Token.

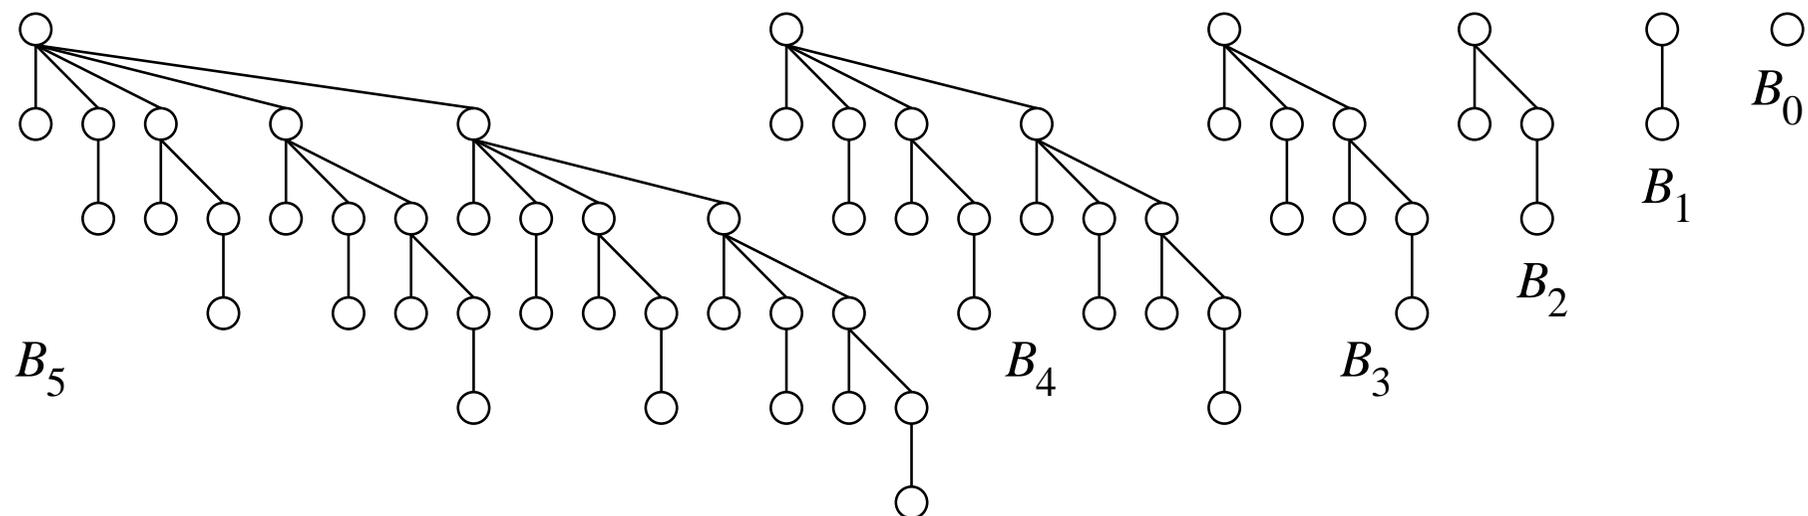
Union-by-rank: Token zahlen für

- union Operationen (ein Token wird frei) und
- durchlaufen alter und neuer Wurzeln.

Am Ende gibt es  $\leq \text{maxRank}$  Wurzeln.

# Warum ist maxRank logarithmisch? – Binomialbäume

$2^k + 1 \times \text{insert}, 1 \times \text{deleteMin} \rightsquigarrow \text{rank } k$



[Vuillemin 1978] PQ nur mit Binomialbäumen,  $T_{\text{decreaseKey}} = O(\log n)$ .

Problem: Schnitte können zu kleinen hochrangigen Bäumen führen

## Kaskadierende Schnitte

**Procedure** decreaseKey( $h$  : Handle,  $k$  : Key)

key( $h$ ) :=  $k$

cascadingCut( $h$ )

**Procedure** cascadingCut( $h$ )

**if**  $h$  is not a root **then**

$p$  := parent( $h$ )

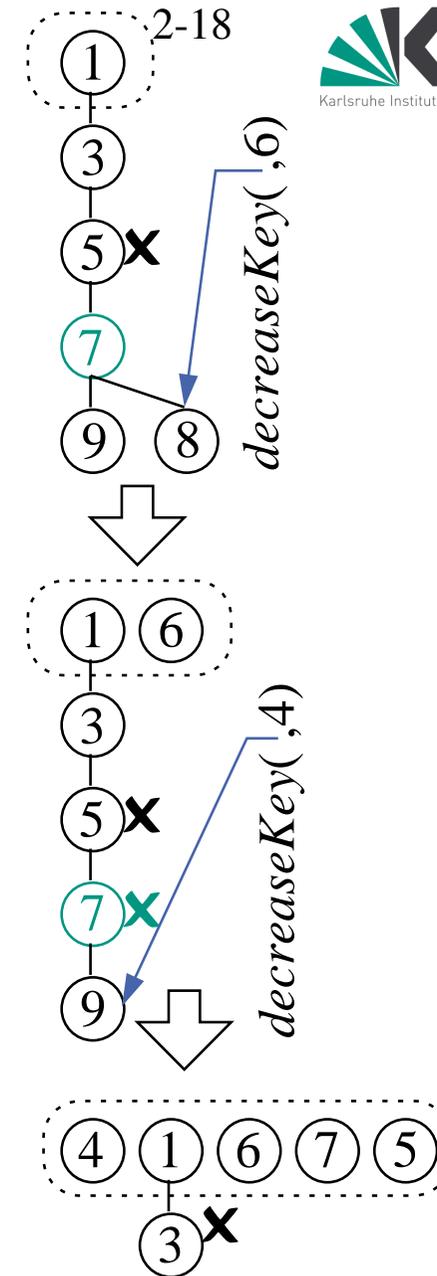
unmark  $h$

cut( $h$ )

**if**  $p$  is marked **then**

cascadingCut( $p$ )

**else** mark  $p$



Wir werden zeigen: kaskadierende Schnitte halten maxRank logarithmisch

Lemma: decreaseKey hat amortisierte Komplexität  $O(1)$

Kontomethode: ( $\approx 1$  Token pro cut oder union)

1 Token für jede Wurzel

2 Token für jeden markierten Knoten

betrachte decreaseKey mit  $k$  konsekutiven markierten Vorgängern:

$2k$  Token werden frei (unmarked nodes)

2 Token für neue Markierung

$k+1$  Token für Ausstattung der neuen Wurzeln

$k+1$  Token für Schnitte

Bleiben 4 Token  $+O(1)$  Kosten für decreaseKey

## Auftritt Herr Fibonacci

$$F_i := \begin{cases} 0 & \text{für } i=0 \\ 1 & \text{für } i=1 \\ F_{i-2} + F_{i-1} & \text{sonst} \end{cases}$$

Bekannt:  $F_{i+1} \geq ((1 + \sqrt{5})/2)^i \geq 1.618^i$  for all  $i \geq 0$ .

Wir zeigen:

Ein Teilbaum mit Wurzel  $v$  mit  $\text{rank}(v) = i$  enthält  $\geq F_{i+2}$  Elemente.

$\Rightarrow$

logarithmische Zeit für deleteMin.

## Beweis:

Betrachte Zeitpunkt als das  $j$ -te Kind  $w_j$  von  $v$  hinzugelinkt wurde:

$w_j$  und  $v$  hatten gleichen Rang  $\geq j - 1$  ( $v$  hatte schon  $j - 1$  Kinder)

$\text{rank}(w_j)$  hat **höchstens um eins abgenommen** (cascading cuts)

$\Rightarrow \text{rank}(w_j) \geq j - 2$  und  $\text{rank}(v) \geq j - 1$

$S_i :=$  untere Schranke für # Knoten mit Wurzel vom Rang  $i$ :

$$S_0 = 1$$

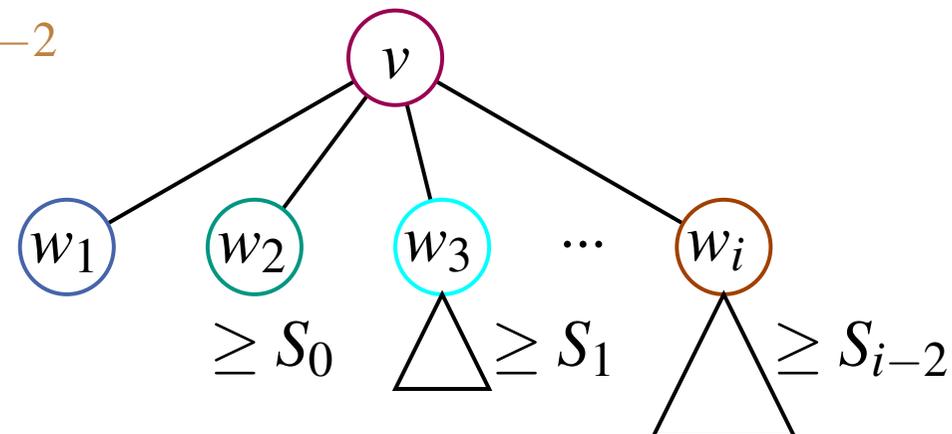
$$S_1 = 2$$

$$S_i \geq 1 + 1 + S_0 + S_1 + \dots + S_{i-2}$$

für  $i \geq 2$

Diese Rekurrenz

hat die Lösung  $S_i \geq F_{i+2}$



## Addressable Priority Queues: Mehr

- Untere Schranke  $\Omega(\log n)$  für deleteMin, vergleichsbasiert.  
Beweis: Übung
- Worst case Schranken: nicht hier
- Monotone** PQs mit **ganzzahligen** Schlüsseln (stay tuned)

### Offene Probleme:

Analyse Pairing Heap, Vereinfachung Fibonacci Heap.

# Zusammenfassung Datenstrukturen

- In dieser Vorlesung Fokus auf Beispiel Prioritätslisten  
(siehe auch kürzeste Wege, externe Algorithmen)
- Heapkonzept trägt weit
- Geschwisterzeiger erlauben Repräsentation beliebiger Bäume mit  
konstanter Zahl Zeiger pro Item.
- Fibonacci heaps als nichttriviales Beispiel für amortisierte Analyse

# Fortgeschrittene Graphenalgorithmen

## 3 Kürzeste Wege

Folien teilweise von Rob van Stee

**Eingabe:** Graph  $G = (V, E)$

Kostenfunktion/Kantengewicht  $c : E \rightarrow \mathbb{R}$

Anfangsknoten  $s$ .

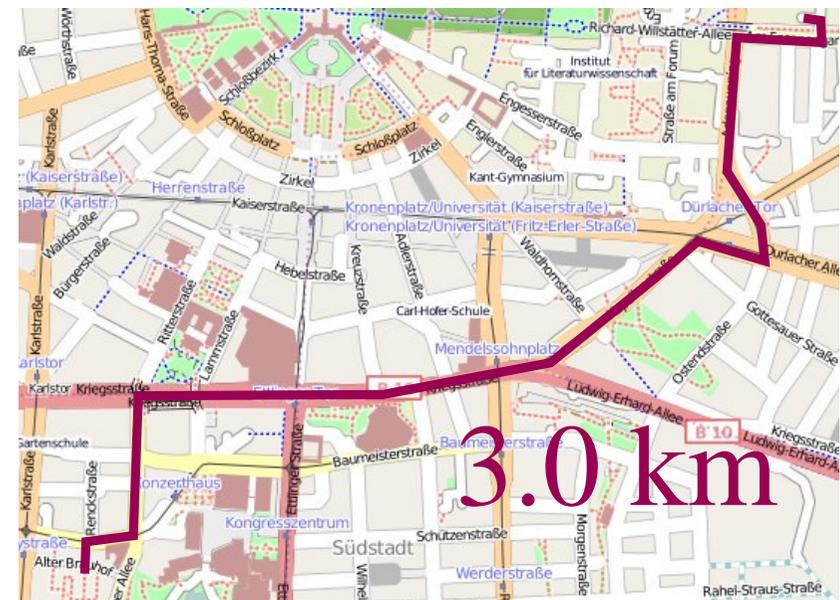
**Ausgabe:** für alle  $v \in V$

Länge  $\mu(v)$  des kürzesten Pfades von  $s$  nach  $v$ ,

$$\mu(v) := \min \{c(p) : p \text{ ist Pfad von } s \text{ nach } v\}$$

$$\text{mit } c(\langle e_1, \dots, e_k \rangle) := \sum_{i=1}^k c(e_i).$$

Oft wollen wir auch „geeignete“ Repräsentation der kürzesten Pfade.



# Allgemeine Definitionen

Wie bei BFS benutzen wir zwei Knotenarrays:

□  $d[v]$  = aktuelle (vorläufige) Distanz von  $s$  nach  $v$

**Invariante:**  $d[v] \geq \mu(v)$

□  $\text{parent}[v]$  = Vorgänger von  $v$

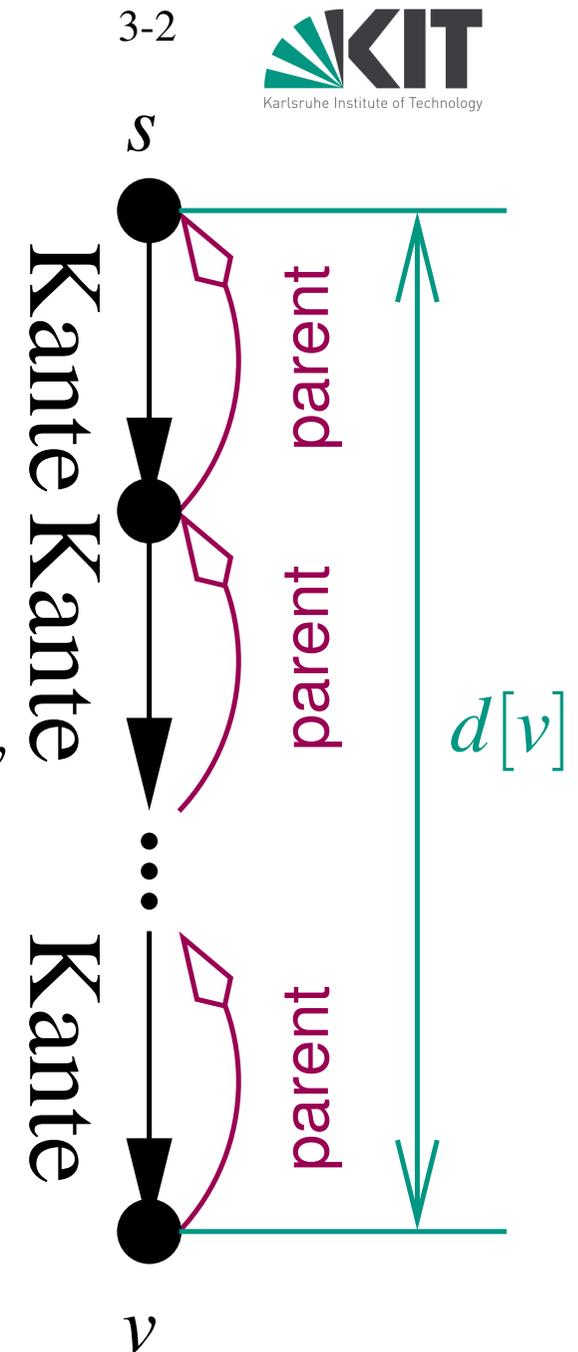
auf dem (vorläufigen) kürzesten Pfad von  $s$  nach  $v$

**Invariante:** dieser Pfad bezeugt  $d[v]$

**Initialisierung:**

$d[s] = 0, \text{parent}[s] = s$

$d[v] = \infty, \text{parent}[v] = \perp$



## Kante $(u, v)$ relaxieren

falls  $d[u] + c(u, v) < d[v]$

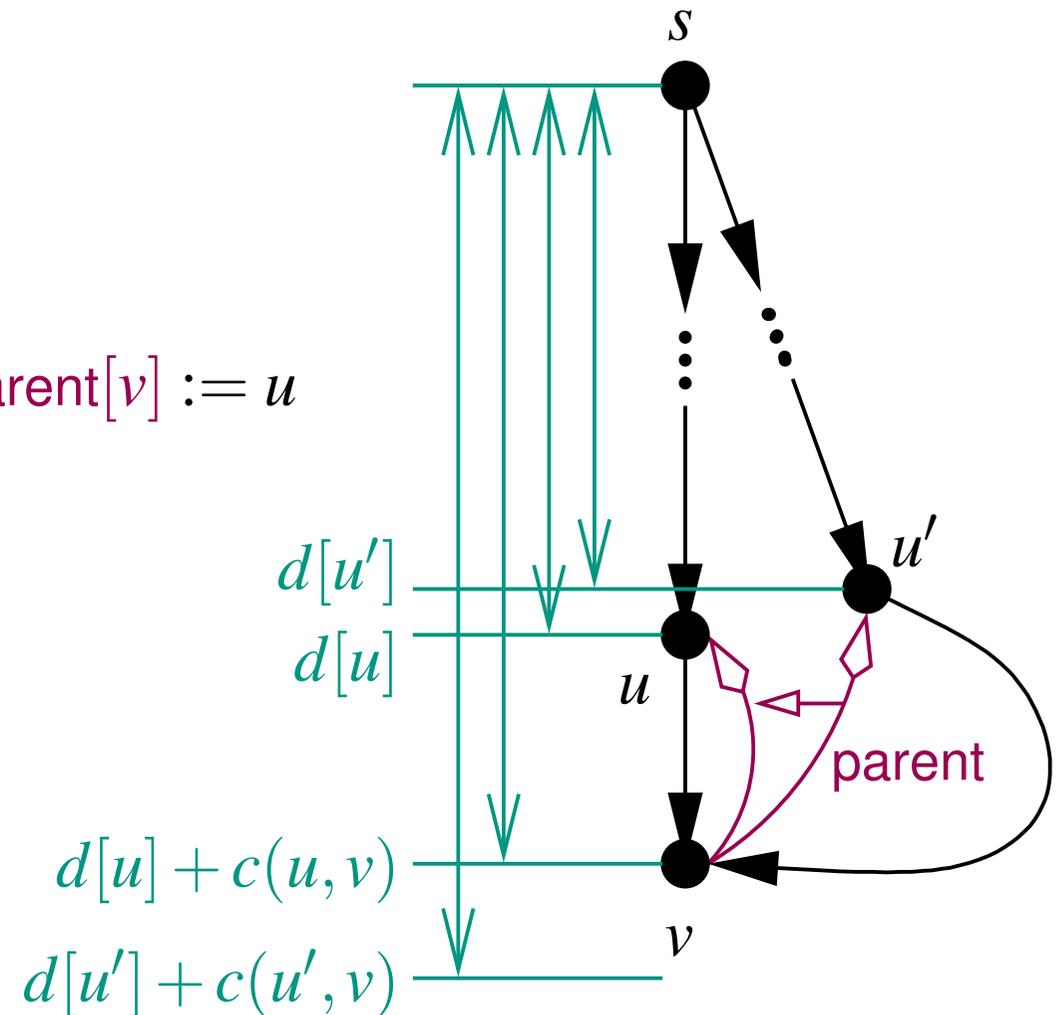
vielleicht  $d[v] = \infty$

setze  $d[v] := d[u] + c(u, v)$  und  $\text{parent}[v] := u$

Invarianten bleiben erhalten!

### Beobachtung:

$d[v]$  Kann sich mehrmals ändern!



# Dijkstra's Algorithmus: Pseudocode

initialize  $d$ , parent

all nodes are non-scanned

**while**  $\exists$  non-scanned node  $u$  with  $d[u] < \infty$

$u :=$  non-scanned node  $v$  with minimal  $d[v]$

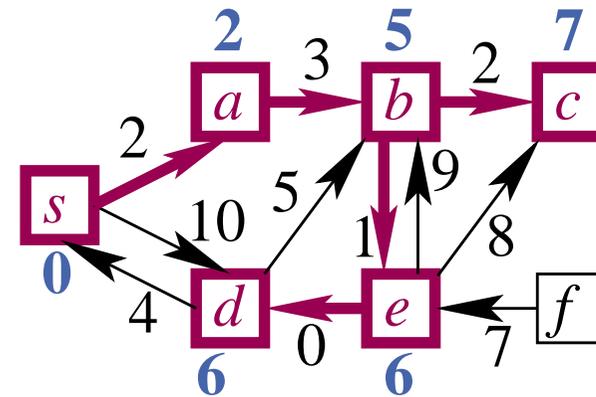
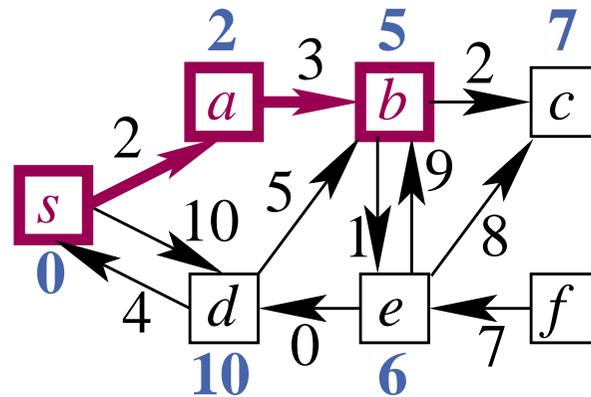
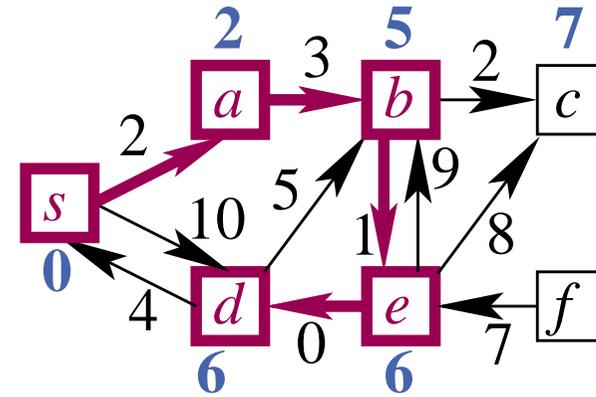
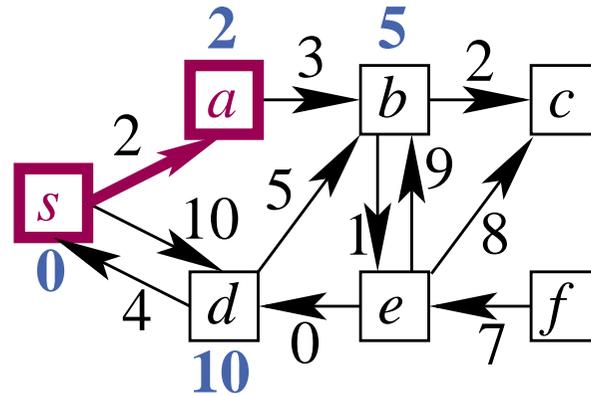
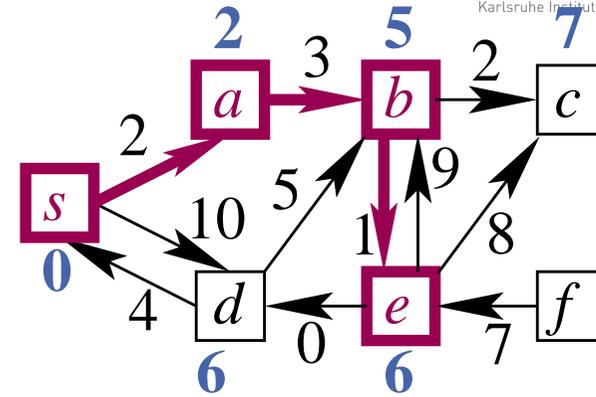
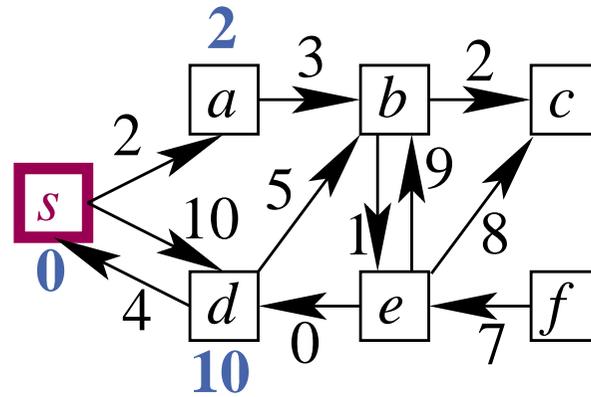
relax all edges  $(u, v)$  out of  $u$

$u$  is scanned now

**Behauptung:** Am Ende definiert  $d$  die optimalen Entfernungen und parent die zugehörigen Wege (siehe Algo I:)

- $v$  erreichbar  $\implies v$  wird irgendwann gescannt
- $v$  gescannt  $\implies \mu(v) = d[v]$

# Beispiel



# Laufzeit

$$T_{\text{Dijkstra}} = O(m \cdot T_{\text{decreaseKey}}(n) + n \cdot (T_{\text{deleteMin}}(n) + T_{\text{insert}}(n)))$$

Mit **Fibonacci-Heapprioritätslisten**:

- insert  $O(1)$
- decreaseKey  $O(1)$
- deleteMin  $O(\log n)$  (amortisiert)

$$\begin{aligned} T_{\text{DijkstraFib}} &= O(m \cdot 1 + n \cdot (\log n + 1)) \\ &= O(m + n \log n) \end{aligned}$$

Aber: konstante Faktoren in  $O(\cdot)$  sind hier größer als bei binären Heaps!

# Laufzeit im Durchschnitt

Bis jetzt:  $\leq m$  decreaseKeys ( $\leq 1 \times$  pro Kante)

Wieviel decreaseKeys **im Durchschnitt**?

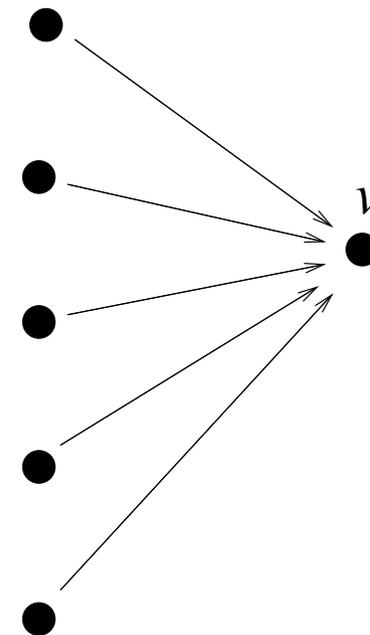
## Modell:

- Beliebiger Graph  $G$
- Beliebiger Anfangsknoten  $s$
- Beliebige Mengen  $C(v)$   
von Kantengewichten für  
eingehende Kanten von Knoten  $v$

**Gemittelt** wird über alle Zuteilungen

$C(v) \rightarrow$  eingehende Kanten von  $v$

**Beispiel:** alle Kosten unabhängig identisch verteilt



$\text{indegree}(v)=5$

$C(v)=\{c_1, \dots, c_5\}$

# Laufzeit im Durchschnitt

Probabilistische Sichtweise: Zufällige gleichverteilte Auswahl der zu mittelnden Eingaben.



wir suchen den **Erwartungswert** der Laufzeit

**Frage:** Unterschied zu erwarteter Laufzeit bei randomisierten Algorithmen ?

# Laufzeit im Durchschnitt

**Satz 1.**  $\mathbb{E}[\#\text{decreaseKey-Operationen}] = O\left(n \log \frac{m}{n}\right)$

Dann

$$\begin{aligned}\mathbb{E}(T_{\text{DijkstraBHeap}}) &= O\left(m + n \log \frac{m}{n} \cdot T_{\text{decreaseKey}}(n) \right. \\ &\quad \left. + n \cdot (T_{\text{deleteMin}}(n) + T_{\text{insert}}(n))\right) \\ &= O\left(m + n \log \frac{m}{n} \log n + n \log n\right) \\ &= O\left(m + n \log \frac{m}{n} \log n\right)\end{aligned}$$

(wir hatten vorher  $T_{\text{DijkstraBHeap}} = O((m + n) \log n)$ )

( $T_{\text{DijkstraFib}} = O(m + n \log n)$  schlechtester Fall)

# Lineare Laufzeit für dichte Graphen

$m = \Omega(n \log n \log \log n) \Rightarrow$  lineare Laufzeit.

(nachrechnen)

Also hier u. U. besser als Fibonacci heaps

**Satz 1.**  $\mathbb{E}[\#decreaseKey\text{-}Operationen] = O\left(n \log \frac{m}{n}\right)$

**Satz 1.**  $\mathbb{E}[\#decreaseKey\text{-Operationen}] = O\left(n \log \frac{m}{n}\right)$

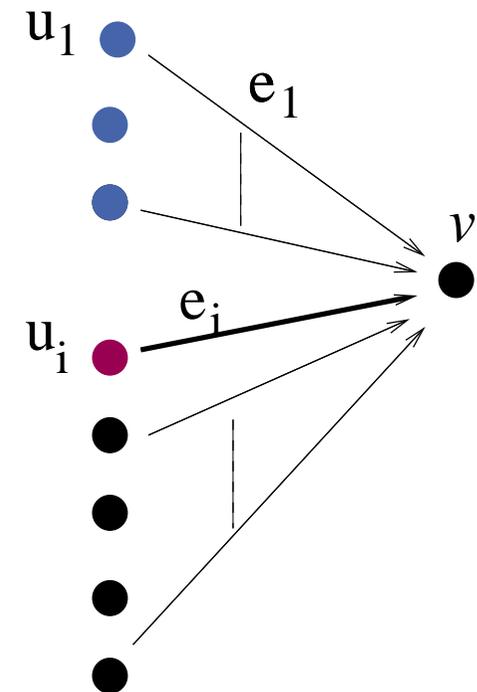
decreaseKey bei Bearbeitung von  $e_i$  nur wenn

$$\mu(u_i) + c(e_i) < \min_{j < i} (\mu(u_j) + c(e_j)).$$

Aber  $\mu(u_i) \geq \mu(u_j)$  für  $j < i$ , also muss gelten:

$$c(e_i) < \min_{j < i} c(e_j).$$

Präfixminimum



**Satz 1.**  $\mathbb{E}[\#decreaseKey\text{-}Operationen] = O\left(n \log \frac{m}{n}\right)$

Kosten in  $C(v)$  erscheinen in **zufälliger Reihenfolge**

Wie oft findet man ein neues Minimum bei zufälliger Reihenfolge?

Harmonische Zahl  $H_k$  (Sect. 2.8, s.u.)

Erstes Minimum: führt zu  $\text{insert}(v)$ .

Also  $\leq H_k - 1 \leq (\ln k + 1) - 1 = \ln k$  erwartete decreaseKeys

**Satz 1.**  $\mathbb{E}[\#\text{decreaseKey-Operationen}] = O\left(n \log \frac{m}{n}\right)$

Für Knoten  $v \leq H_k - 1 \leq \ln k$  decreaseKeys (erwartet) mit  $k = \text{indegree}(v)$ .

Insgesamt

$$\sum_{v \in V} \ln \text{indegree}(v) \leq n \ln \frac{m}{n}$$

(wegen Konkavität von  $\ln x$ )

# Präfixminima einer Zufallsfolge

Definiere Zufallsvariable  $M_n$  als Anzahl Präfixminima einer Folge von  $n$  verschiedenen Zahlen (in Abhängigkeit von einer Zufallspermutation)

Definiere Indikatorzufallsvariable  $I_i := 1$  gdw. die  $i$ -te Zahl ein Präfixminimum ist.

$$\begin{aligned}
 \mathbb{E}[M_n] &= \mathbb{E}\left[\sum_{i=1}^n I_i\right] \stackrel{\text{Lin. E}[\cdot]}{=} \sum_{i=1}^n \mathbb{E}[I_i] \\
 &= \sum_{i=1}^n \frac{1}{i} = H_n \text{ wegen } \mathbb{P}[I_i = 1] = \frac{1}{i}
 \end{aligned}$$

$$\underbrace{x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n}_{<x_i?}$$

# Monotone ganzzahlige Prioritätslisten

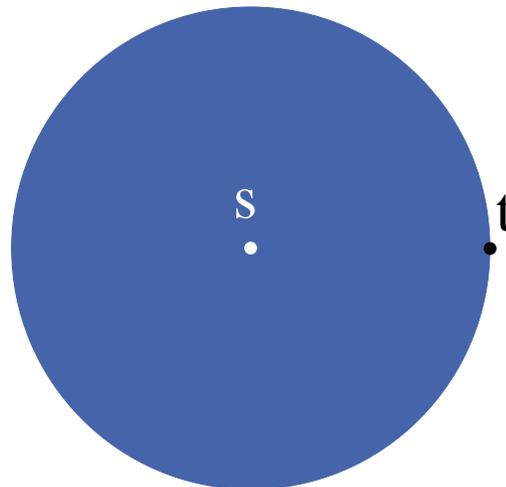
Grundidee: Datenstruktur auf Anwendung **zuschneiden**

Dijkstra's Algorithmus benutzt die **Prioritätsliste monoton**:

Operationen insert und decreaseKey benutzen Distanzen der Form

$$d[u] + c(e)$$

Dieser Wert **nimmt ständig zu**



# Monotone ganzzahlige Prioritätslisten

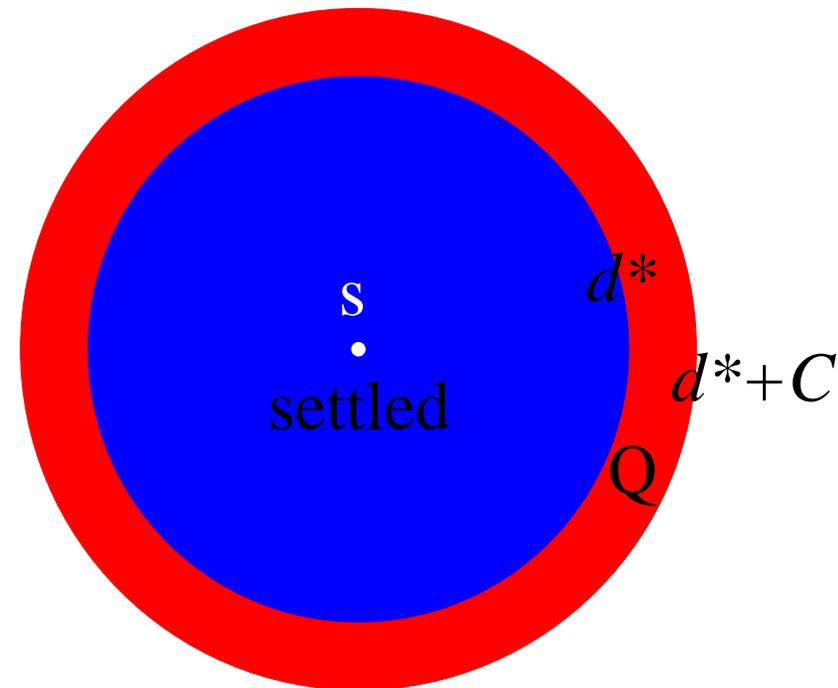
**Annahme:** Alle Kantengewichte sind ganzzahlig und im Intervall  $[0, C]$

$$\implies \forall v \in V : d[v] \leq (n - 1)C$$

Es gilt sogar:

Sei  $d^*$  der letzte Wert,  
der aus  $Q$  entfernt wurde.

In  $Q$  sind immer  
nur Knoten mit Distanzen im  
Intervall  $[d^*, d^* + C]$ .

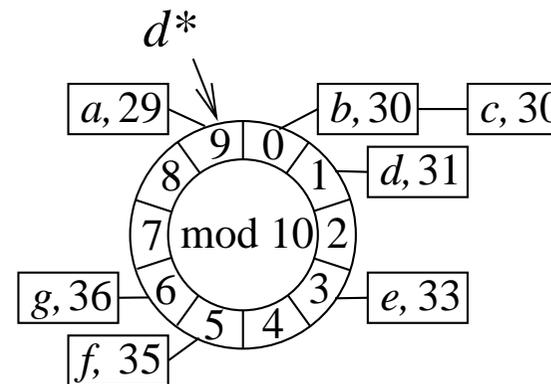


# Bucket-Queue

Zyklisches Array  $B$  von  $C + 1$  doppelt verketteten Listen

Knoten mit Distanz  $d[v]$  wird in  $B[d[v] \bmod (C + 1)]$  gespeichert.

Bucket queue with  $C = 9$



Content=

$\langle (a,29), (b,30), (c,30), (d,31) \rangle$   
 $\langle (e,33), (f,35), (g,36) \rangle$

# Operationen

Initialisierung:  $C + 1$  leere Listen,  $d^* = 0$

**insert(v)**: fügt  $v$  in  $B[d[v] \bmod (C + 1)]$  ein

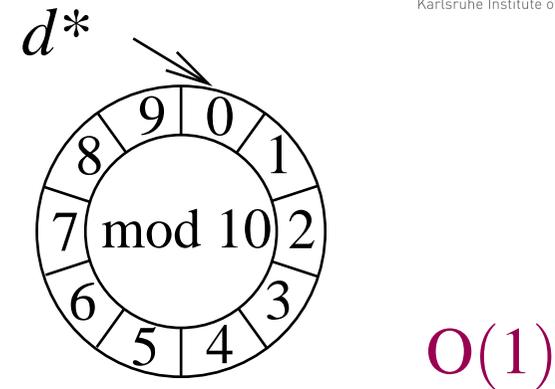
**decreaseKey(v)**: entfernt  $v$  aus seiner Liste und fügt es ein in  $B[d[v] \bmod (C + 1)]$

**deleteMin**: fängt an bei Bucket  $B[d^* \bmod (C + 1)]$ . Falls der leer ist,  $d^* := d^* + 1$ , wiederhole. erfordert Monotonizität!

$d^*$  nimmt höchstens  $nC$  mal zu, höchstens  $n$  Elemente werden insgesamt aus  $Q$  entfernt  $\Rightarrow$

Gesamtkosten deleteMin-Operationen =  $O(n + nC) = O(nC)$ .

Genauer:  $O(n + \text{maxPathLength})$



# Laufzeit Dijkstra mit Bucket-Queues

$$\begin{aligned} T_{\text{Dijkstra}} &= O(m \cdot T_{\text{decreaseKey}}(n) \\ &\quad + \text{Kosten deleteMin-Operationen} \\ &\quad + n \cdot T_{\text{insert}}(n)) \end{aligned}$$

$$\begin{aligned} T_{\text{DijkstraBQ}} &= O(m \cdot 1 + nC + n \cdot 1) \\ &= O(m + nC) \text{ oder auch} \\ &= O(m + \text{maxPathLength}) \end{aligned}$$

Mit Radix-Heaps finden wir sogar  $T_{\text{DijkstraRadix}} = O(m + n \cdot \log C)$

Idee: nicht alle Buckets gleich groß machen

# Radix-Heaps

Wir verwenden die Buckets  $-1$  bis  $K$ , für  $K = 1 + \lfloor \log C \rfloor$

$d^*$  = die zuletzt aus  $Q$  entfernte Distanz

Für jeden Knoten  $v \in Q$  gilt  $d[v] \in [d^*, \dots, d^* + C]$ .

Betrachte **binäre Repräsentation** der möglichen Distanzen in  $Q$ .

Nehme zum Beispiel  $C = 9$ , binär 1001. Dann  $K = 4$ .

Beispiel 1:  $d^* = 10000$ , dann  $\forall v \in Q : d[v] \in [10000, 11001]$

Beispiel 2:  $d^* = 11101$ , dann  $\forall v \in Q : d[v] \in [11101, 100110]$

Speichere  $v$  in Bucket  $B[i]$  falls  $d[v]$  und  $d^*$  sich **zuerst an der  $i$ ten Stelle unterscheiden**, (in  $B[K]$  falls  $i > K$ , in  $B[-1]$  falls sie sich nicht unterscheiden)

## Definition $msd(a, b)$

Die **Position** der **höchstwertigen Binärziffer** wo  $a$  und  $b$  sich unterscheiden

$a$	1100 <b>1</b> 010	10101 <b>0</b> 0	1110110
$b$	1100 <b>0</b> 101	10101 <b>1</b> 0	1110110
$msd(a, b)$	3	1	-1

$msd(a, b)$  können wir mit Maschinenbefehlen sehr schnell berechnen

# Radix-Heap-Invariante

$v$  ist gespeichert in Bucket  $B[i]$  wo  $i = \min(\text{msd}(d^*, d[v]), K)$ .

Beispiel 1:  $d^* = 10000$ ,  $C = 9$ ,  $K = 4$

Bucket	$d[v]$ binär	$d[v]$
-1	10000	16
0	10001	17
1	1001*	18,19
2	101**	20–23
3	11***	24–25
4	-	-

(In Bucket 4 wird nichts gespeichert)

# Radix-Heap-Invariante

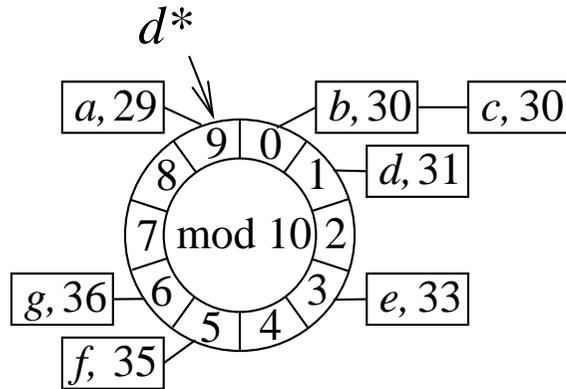
$v$  ist gespeichert in Bucket  $B[i]$  wo  $i = \min(\text{msd}(d^*, d[v]), K)$ .

Beispiel 2:  $d^* = 11101$ ,  $C = 9$ , dann  $K = 4$

Bucket	$d[v]$ binär	$d[v]$
-1	11101	29
0	-	-
1	1111*	30,31
2	-	-
3	-	-
4	100000 und höher	32 und höher

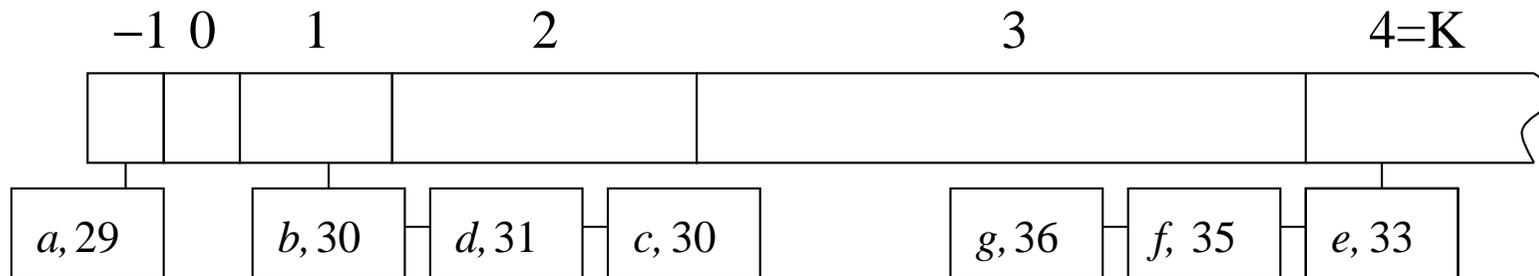
Falls  $d[v] \geq 32$ , dann  $\text{msd}(d^*, d[v]) > 4!$

# Bucket-Queues und Radix-Heaps



Bucket queue with  $C = 9$

Content=  
 $\langle (a,29), (b,30), (c,30), (d,31), (e,33), (f,35), (g,36) \rangle$



Binary Radix Heap

## Radix Heap: deleteMin

**Function** deleteMin: Element

**if**  $B[-1] = \emptyset$

$i := \min \{ j \in 0..K : B[j] \neq \emptyset \}$

move  $\min B[i]$  to  $B[-1]$  and to  $d^*$

**foreach**  $e \in B[i]$  **do** // exactly here invariant is violated !

    move  $e$  to  $B[\min(\text{msd}(d^*, d[e]), K)]$

result :=  $B[-1].\text{popFront}$

**return** result

$B[0], \dots, B[i-1]$ : leer, also nichts zu tun.

$B[i+1], \dots, B[K]$ : msd bleibt erhalten, weil altes und neues  $d^*$

**gleich** für alle Bits  $j > i$

## Buckets $j > i$ bei Änderung von $d^*$

Beispiel:  $d^* = 10000$ ,  $C = 9$ ,  $K = 4$ .

Neues  $d^* = 10010$ , war in Bucket 1

Bucket	$d^* = 10000$		$d^* = 10010$	
	$d[v]$ binär	$d[v]$	$d[v]$ binär	$d[v]$
-1	10000	16	10010	18
0	10001	17	10011	19
1	1001*	18,19	-	-
2	101**	20–23	101**	20-23
3	11***	24–25	11***	24-27
4	-	-	-	-

## Bucket $B[i]$ bei Änderung von $d^*$

**Lemma:** Elemente  $x$  aus  $B[i]$  gehen zu Buckets mit **kleineren** Indices

Wir zeigen nur den Fall  $i < K$ .

Sei  $d_o^*$  der alte Wert von  $d^*$ .

Case  $i < K$

	$i$	$0$
$d_o^*$	$\alpha$	$0$
$d^*$	$\alpha$	$1$
$x$	$\alpha$	$1$

## Kosten der deleteMin-Operationen

Bucket  $B[i]$  finden:  $O(i)$

Elemente aus  $B[i]$  verschieben:  $O(|B[i]|)$

Insgesamt  $O(K + |B[i]|)$  falls  $i \geq 0$ ,  $O(1)$  falls  $i = -1$

Verschiebung erfolgt immer nach **kleineren** Indices

Wir zahlen dafür **schon beim insert** (amortisierte Analyse):

es gibt höchstens  $K$  Verschiebungen eines Elements

# Laufzeit Dijkstra mit Radix-Heaps

Insgesamt finden wir amortisiert

$$\square T_{\text{insert}}(n) = O(K)$$

$$\square T_{\text{deleteMin}}(n) = O(K)$$

$$\square T_{\text{decreaseKey}}(n) = O(1)$$

$$T_{\text{Dijkstra}} = O(m \cdot T_{\text{decreaseKey}}(n) + n \cdot (T_{\text{deleteMin}}(n) + T_{\text{insert}}(n)))$$

$$T_{\text{DijkstraRadix}} = O(m + n \cdot (K + K)) = O(m + n \cdot \log C)$$

# Lineare Laufzeit für zufällige Kantengewichte

Vorher gesehen: Dijkstra mit binary heaps hat lineare Laufzeit für dichte Graphen ( $m > n \log n \log \log n$ )

Letzte Folie:  $T_{\text{DijkstraRadix}} = O(m + n \cdot \log C)$

Jetzt: Dijkstra mit Radix-Heaps hat lineare Laufzeit ( $O(m + n)$ ) falls Kantenkosten identisch uniform verteilt in  $0..C$

– wir brauchen nur eine kleine Änderung im Algorithmus

# Änderung im Algorithmus für zufällige Kantengewichte

Vorbereitung von  $c_{\min}^{\text{in}}(v) := \min \{c((u, v) : (u, v) \in E\}$  leichtestes eingehendes Kantengewicht.

Beobachtung:  $d[v] \leq d^* + c_{\min}^{\text{in}}(v)$

$\implies d[v] = \mu(v)$ .

$\implies$  schiebe  $v$  in Menge  $F$  ungesannter Knoten mit korrekter Distanz

Knoten in  $F$  werden bei nächster Gelegenheit gescannt.

( $\approx F$  als Erweiterung von  $B[-1]$ .)

## Analyse

Ein Knoten  $v$  kommt **nie** in einem Bucket  $i$  mit  $i < \log c_{\min}^{\text{in}}(v)$

Also wird  $v$  höchstens  $K + 1 - \log c_{\min}^{\text{in}}(v)$  mal verschoben

**Kosten von Verschiebungen** sind dann insgesamt höchstens

$$\sum_v (K - \log c_{\min}^{\text{in}}(v) + 1) = n + \sum_v (K - \log c_{\min}^{\text{in}}(v)) \leq n + \sum_e (K - \log c(e)).$$

$K - \log c(e)$  = Anzahl Nullen am Anfang der binären Repräsentation von  $c(e)$  als  $K$ -Bit-Zahl.

$$\mathbb{P}(K - \log c(e) = i) = 2^{-i} \quad \Rightarrow \quad \mathbb{E}(K - \log c(e)) = \sum_{i \geq 0} i 2^{-i} \leq 2$$

$$\text{Laufzeit} = O(m + n)$$

# All-Pairs Shortest Paths

Bis jetzt gab es immer einen bestimmten Anfangsknoten  $s$

Wie können wir kürzeste Pfade für **alle** Paare  $(u, v)$  in  $G$  bestimmen?

Annahme: negative Kosten erlaubt, aber keine negativen **Kreise**

Lösung 1:  $n$  mal Bellman-Ford ausführen

... Laufzeit  $O(n^2m)$

Lösung 2: **Knotenpotentiale**

... Laufzeit  $O(nm + n^2 \log n)$ , deutlich schneller

# Knotenpotentiale

Jeder Knoten bekommt ein Potential  $\text{pot}(v)$

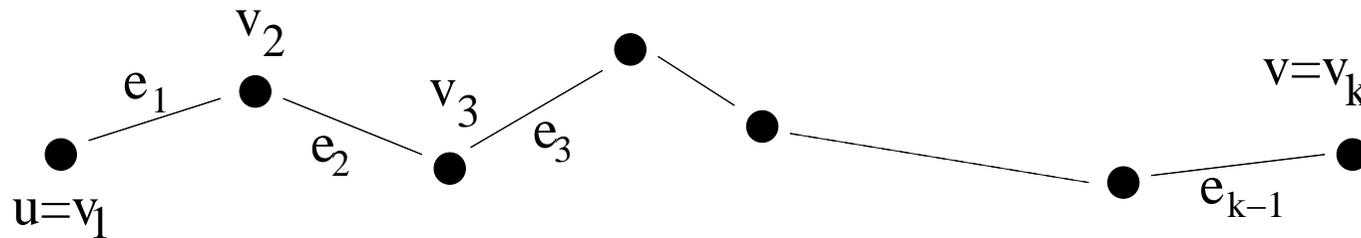
Mit Hilfe der Potentiale definieren wir **reduzierte Kosten**  $\bar{c}(e)$  für Kante  $e = (u, v)$  als

$$\bar{c}(e) = \text{pot}(u) + c(e) - \text{pot}(v).$$

Mit diesen Kosten finden wir die **gleichen** kürzesten Pfade wie vorher!

Gilt für **alle** möglichen Potentiale – wir können sie also frei definieren

# Knotenpotentiale



Sei  $p$  ein Pfad von  $u$  nach  $v$  mit Kosten  $c(p)$ . Dann

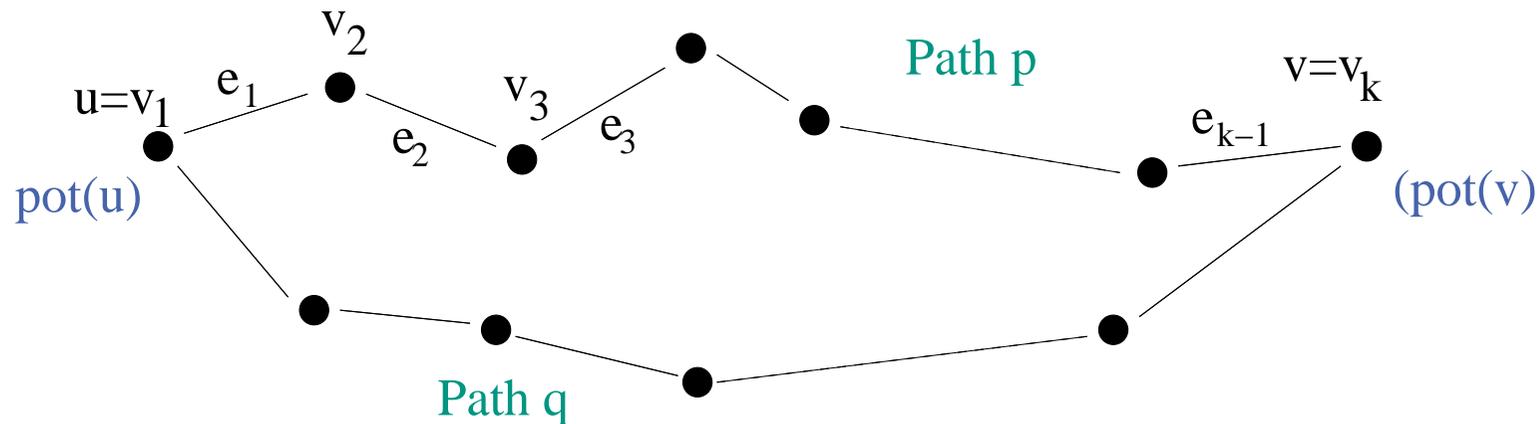
$$\begin{aligned}
 \bar{c}(p) &= \sum_{i=1}^{k-1} \bar{c}(e_i) = \sum_{i=1}^{k-1} (\text{pot}(v_i) + c(e_i) - \text{pot}(v_{i+1})) \\
 &= \text{pot}(v_1) + \sum_{i=1}^{k-1} c(e_i) - \text{pot}(v_k) \\
 &= \text{pot}(v_1) + c(p) - \text{pot}(v_k).
 \end{aligned}$$

# Knotenpotentiale

Sei  $p$  ein Pfad von  $u$  nach  $v$  mit Kosten  $c(p)$ . Dann

$$\bar{c}(p) = \text{pot}(v_1) + c(p) - \text{pot}(v_k).$$

Sei  $q$  ein anderer  $u$ - $v$ -Pfad, dann  $c(p) \leq c(q) \Leftrightarrow \bar{c}(p) \leq \bar{c}(q)$ .



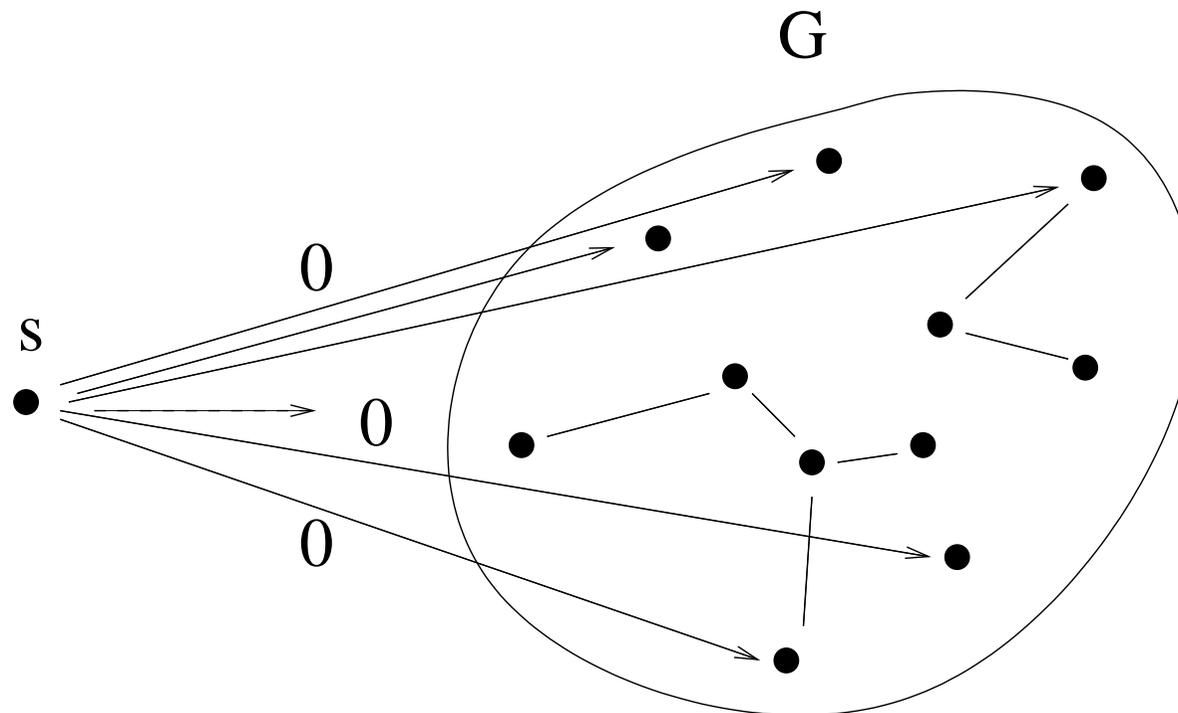
**Definition:**  $\mu(u, v)$  = kürzeste Distanz von  $u$  nach  $v$

# Hilfsknoten

Wir fügen einen **Hilfsknoten  $s$**  an  $G$  hinzu

Für alle  $v \in V$  fügen wir eine Kante  $(s, v)$  hinzu mit Kosten 0

Berechne kürzeste Pfade **von  $s$  aus** mit Bellman-Ford



## Definition der Potentiale

Definiere  $\text{pot}(v) := \mu(v)$  für alle  $v \in V$

Jetzt sind die reduzierten Kosten alle **nicht negativ**: also können wir Dijkstra benutzen! (Evtl.  $s$  wieder entfernen...)

- Keine negativen Kreise, also  $\text{pot}(v)$  wohldefiniert
- Für beliebige Kante  $e = (u, v)$  gilt

$$\mu(u) + c(e) \geq \mu(v)$$

deshalb

$$\bar{c}(e) = \underbrace{\mu(u) + c(e)}_{\geq \mu(v)} - \mu(v) \geq 0$$

# Algorithmus

## All-Pairs Shortest Paths in the Absence of Negative Cycles

neuer Knoten  $s$

**foreach**  $v \in V$  **do** füge Kante  $(s, v)$  ein (Kosten 0) //  $O(n)$

pot:=  $\mu$ := BellmanFordSSSP( $s, c$ ) //  $O(nm)$

**foreach** Knoten  $x \in V$  **do** //  $O(n(m + n \log n))$

$\bar{\mu}(x, \cdot)$ := DijkstraSSSP( $x, \bar{c}$ )

// zurück zur ursprünglichen Kostenfunktion

**foreach**  $e = (v, w) \in V \times V$  **do** //  $O(n^2)$

$\mu(v, w)$ :=  $\bar{\mu}(v, w) + \text{pot}(w) - \text{pot}(v)$

# Laufzeit

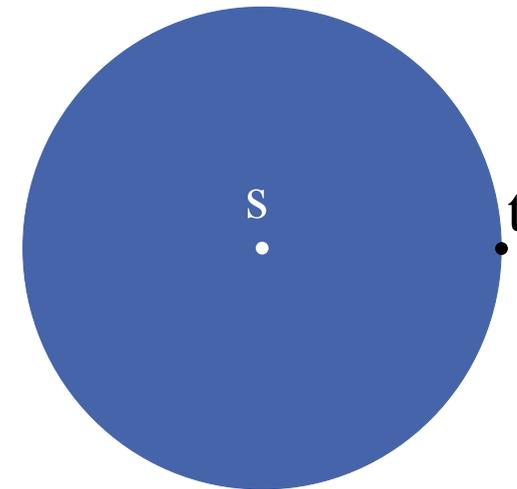
- $s$  hinzufügen:  $O(n)$
- Postprocessing:  $O(n^2)$  (zurück zu den ursprünglichen Kosten)
- $n$  mal Dijkstra dominiert

$$\text{Laufzeit } O(n(m + n \log n)) = O(nm + n^2 \log n)$$

Auch parallelisierbar: par. Bellman–Ford + unabhängige SSSP-Suchen. Speicherplatz?

## Distanz zu einem Zielknoten $t$

Was machen wir, wenn wir nur die Distanz von  $s$  zu einem bestimmten Knoten  $t$  wissen wollen?



### Trick 0:

Dijkstra hört auf, wenn  $t$  aus  $Q$  entfernt wird

Spart "im Durchschnitt" Hälfte der Scans

Frage: Wieviel spart es (meist) beim Europa-Navi?



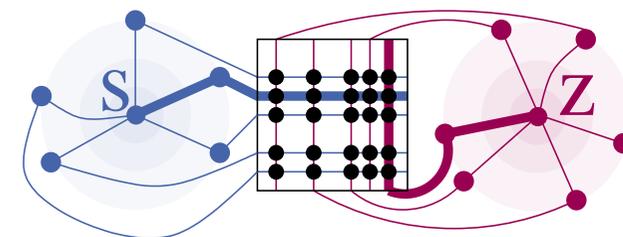
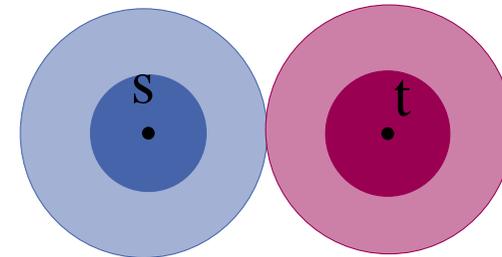
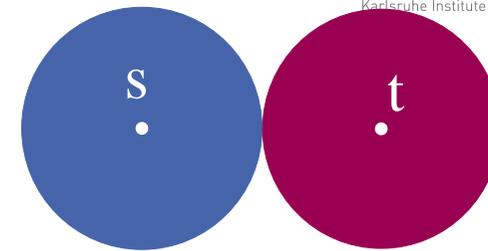
# Ideen für Routenplanung

Vorwärts + Rückwärtsuche

Zielgerichtete Suche

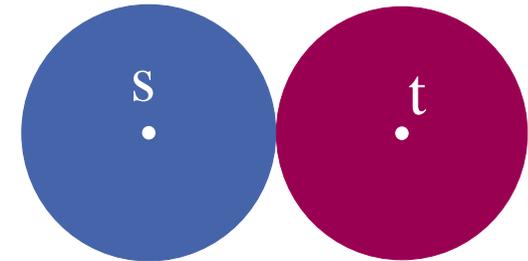
Hierarchien ausnutzen 

Teilabschnitte tabellieren 



# Bidirektionale Suche

Idee: Suche abwechselnd  $s$  und  $t$



Vorwärtssuche auf normalem Graph  $G = (V, E)$

Rückwärtssuche auf Rückwärtsgraph  $G^r = (V, E^r)$

(Suchrichtungen wechseln in jedem Schritt)

Vorläufige kürzeste Distanz wird in jedem Schritt gespeichert:

$$d[s, t] = \min(d[s, t], d_{\text{forward}}[u] + d_{\text{backward}}[u])$$

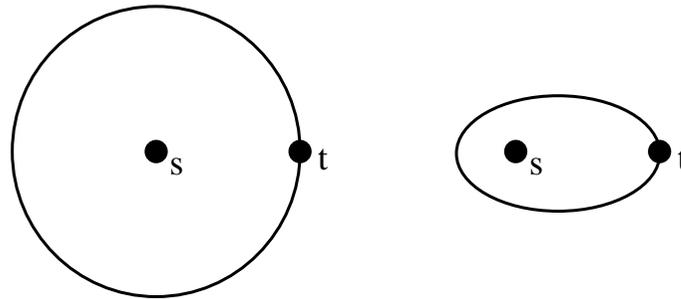
**Abbruchkriterium:**

Suche scannt Knoten, der in anderer Richtung bereits gescannt wurde.

$$d[s, t] \Rightarrow \mu(s, t)$$

# $A^*$ -Suche

Idee: suche “in die Richtung von  $t$ ”

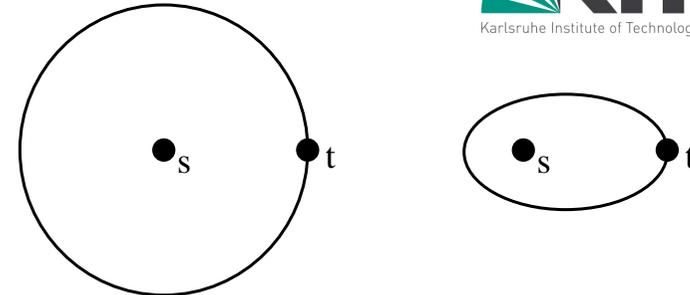


Annahme: Wir kennen eine Funktion  $f(v)$  die  $\mu(v, t)$  schätzt  $\forall v$

Definiere  $\text{pot}(v) = f(v)$  und  $\bar{c}(u, v) = c(u, v) + f(v) - f(u)$

[Oder: in Dijkstra's Algorithmus, entferne nicht  $v$  mit minimalem  $d[v]$  aus  $Q$ , sondern  $v$  mit minimalem  $d[v] + f[v]$ ]

# A\*-Suche



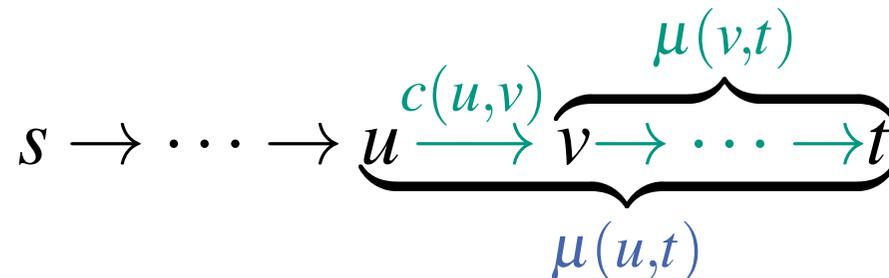
Idee: suche "in die Richtung von  $t$ "

Annahme: wir kennen eine Funktion  $f(v)$  die  $\mu(v, t)$  schätzt  $\forall v$

Definiere  $\text{pot}(v) = f(v)$  und  $\bar{c}(u, v) = c(u, v) + f(v) - f(u)$

Beispiel:  $f(v) = \mu(v, t)$ .

Dann gilt:  $\bar{c}(u, v) = c(u, v) + \mu(v, t) - \mu(u, t) = 0$  falls  $(u, v)$  auf dem kürzesten Pfad von  $s$  nach  $t$  liegt.



Also scannt Dijkstra nur die Knoten auf diesem Pfad!

## Benötigte Eigenschaften von $f(v)$

- Konsistenz (reduzierte Kosten nicht negativ):

$$c(e) + f(v) \geq f(u) \quad \forall e = (u, v)$$

- $f(v) \leq \mu(v, t) \quad \forall v \in V$

- $f(t) = 0$  dann können wir aufhören, wenn  $t$  aus  $Q$  entfernt wird

Sei  $p$  irgendein Pfad von  $s$  nach  $t$ .

Alle Kanten auf  $p$  sind relaxiert?  $\Rightarrow d[t] \leq c(p)$ .

Sonst:  $\exists v \in p \cap Q$ , und  $d[t] + f(t) \leq d[v] + f(v)$  weil  $t$  schon entfernt wurde. Deshalb

$$d[t] = d[t] + f(t) \leq d[v] + f(v) \leq d[v] + \mu(v, t) \leq c(p)$$

## Wie finden wir $f(v)$ ?

Wir brauchen Heuristiken für  $f(v)$ .

Strecke im Straßennetzwerk:  $f(v) = \text{euklidischer Abstand } ||v - t||_2$

bringt deutliche aber nicht überragende Beschleunigung

Fahrzeit:  $\frac{||v - t||_2}{\text{Höchstgeschwindigkeit}}$

praktisch nutzlos

Noch besser aber mit Vorberechnung: **Landmarks**

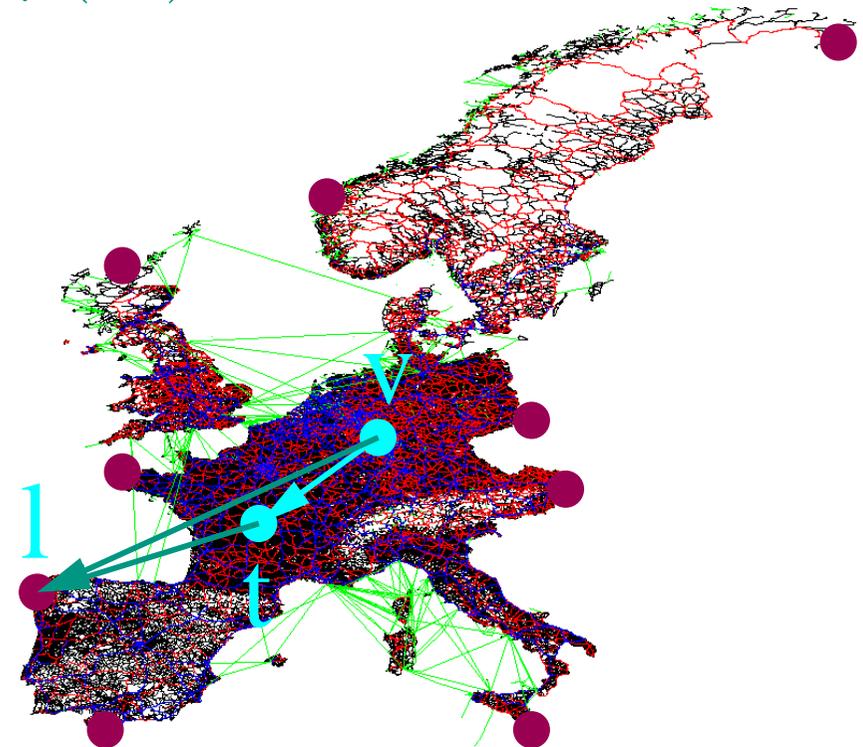
# Landmarks [Goldberg Harrelson 2003]

**Vorbereitung:** Wähle Landmarkmenge  $L$ .  $\forall \ell \in L, v \in V$   
berechne/speichere  $\mu(v, \ell)$ .

**Query:** Suche Landmark  $\ell \in L$  "hinter" dem Ziel.

Benutze untere Schranke  $f_\ell(v) = \mu(v, \ell) - \mu(t, \ell)$

- + Konzeptuell einfach
- + Erhebliche Beschleunigungen  
( $\approx$  Faktor 20 im Mittel)
- + Kombinierbar mit anderen Techniken
- Landmarkauswahl kompliziert
- hoher Platzverbrauch



# Zusammenfassung Kürzeste Wege

- Nichttriviale Beispiele für Analyse im Mittel. Ähnlich für MST
- Monotone, ganzzahlige Prioritätslisten als Beispiel wie Datenstrukturen auf Algorithmus angepasst werden
- Knotenpotentiale allgemein nützlich in Graphenalgorithmen
- Aktuelle Forschung trifft klassische Algorithmik

# 4 Anwendungen von DFS

## Tiefensuchschema für $G = (V, E)$

unmark all nodes; **init**

**foreach**  $s \in V$  **do**

**if**  $s$  is not marked **then**

mark  $s$

// make  $s$  a root and grow

**root**( $s$ )

// a new DFS-tree rooted at it.

**DFS**( $s, s$ )

**Procedure** **DFS**( $u, v : \text{NodeId}$ )

// Explore  $v$  coming from  $u$ .

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

**if**  $w$  is marked **then** **traverseNonTreeEdge**( $v, w$ )

**else** **traverseTreeEdge**( $v, w$ )

mark  $w$

**DFS**( $v, w$ )

**backtrack**( $u, v$ ) // return from  $v$  along the incoming edge

# DFS Nummerierung

init:  $\text{dfsPos} = 1 : 1..n$

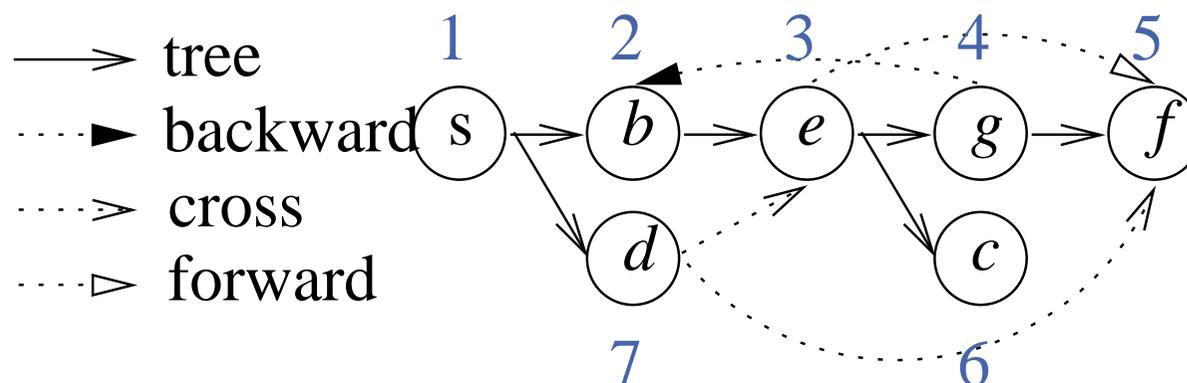
root( $s$ ):  $\text{dfsNum}[s] := \text{dfsPos}++$

traverseTreeEdge( $v, w$ ):  $\text{dfsNum}[w] := \text{dfsPos}++$

$$u \prec v \Leftrightarrow \text{dfsNum}[u] < \text{dfsNum}[v] .$$

## Beobachtung:

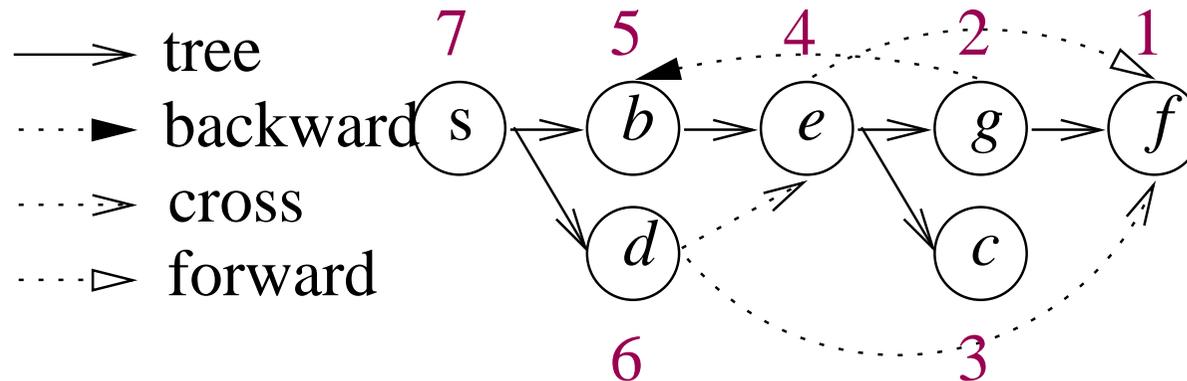
Knoten auf dem Rekursionsstapel sind bzgl.,  $\prec$  sortiert



# Fertigstellungszeit

init: finishingTime = 1 : 1..n

backtrack(u, v): finishTime[v] := finishingTime++



# Starke Zusammenhangskomponenten

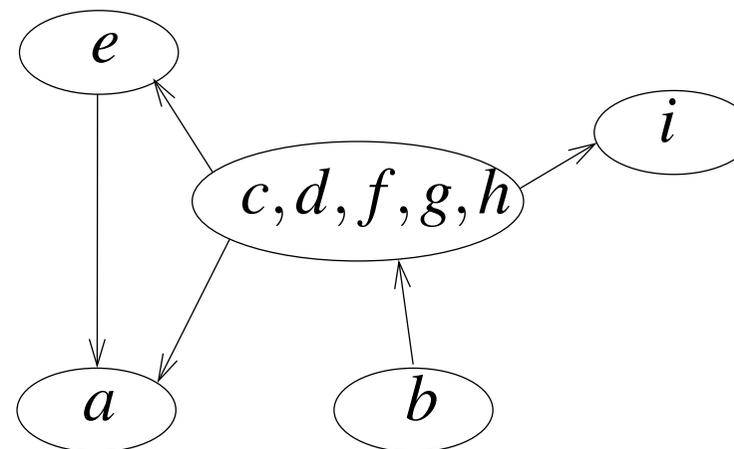
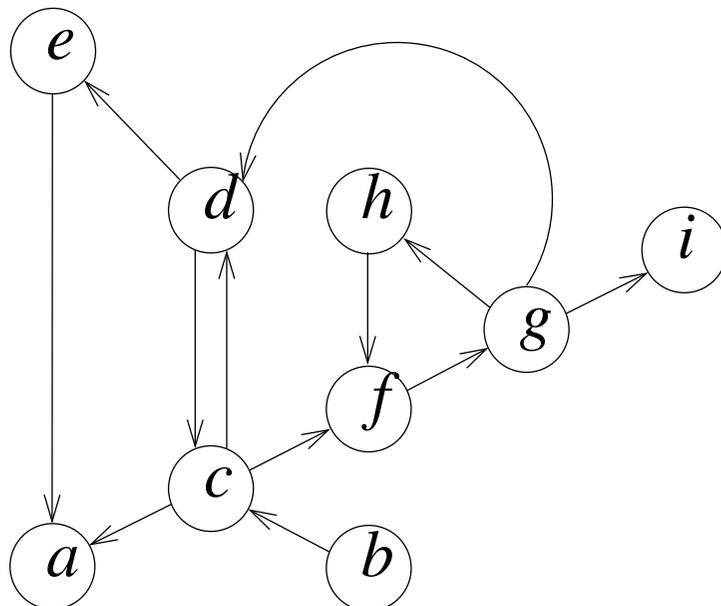
Betrachte die Relation  $\overset{*}{\leftrightarrow}$  mit

$u \overset{*}{\leftrightarrow} v$  falls  $\exists$  Pfad  $\langle u, \dots, v \rangle$  und  $\exists$  Pfad  $\langle v, \dots, u \rangle$ .

**Beobachtung:**  $\overset{*}{\leftrightarrow}$  ist Äquivalenzrelation

Übung

Die Äquivalenzklassen von  $\overset{*}{\leftrightarrow}$  bezeichnet man als **starke Zusammenhangskomponenten**.



# Starke Zusammenhangskomponenten – Abstrakter Algorithmus

$G_c := (V, \emptyset = E_c)$

**foreach** edge  $e \in E$  **do**

**invariant** SCCs of  $G_c$  are known

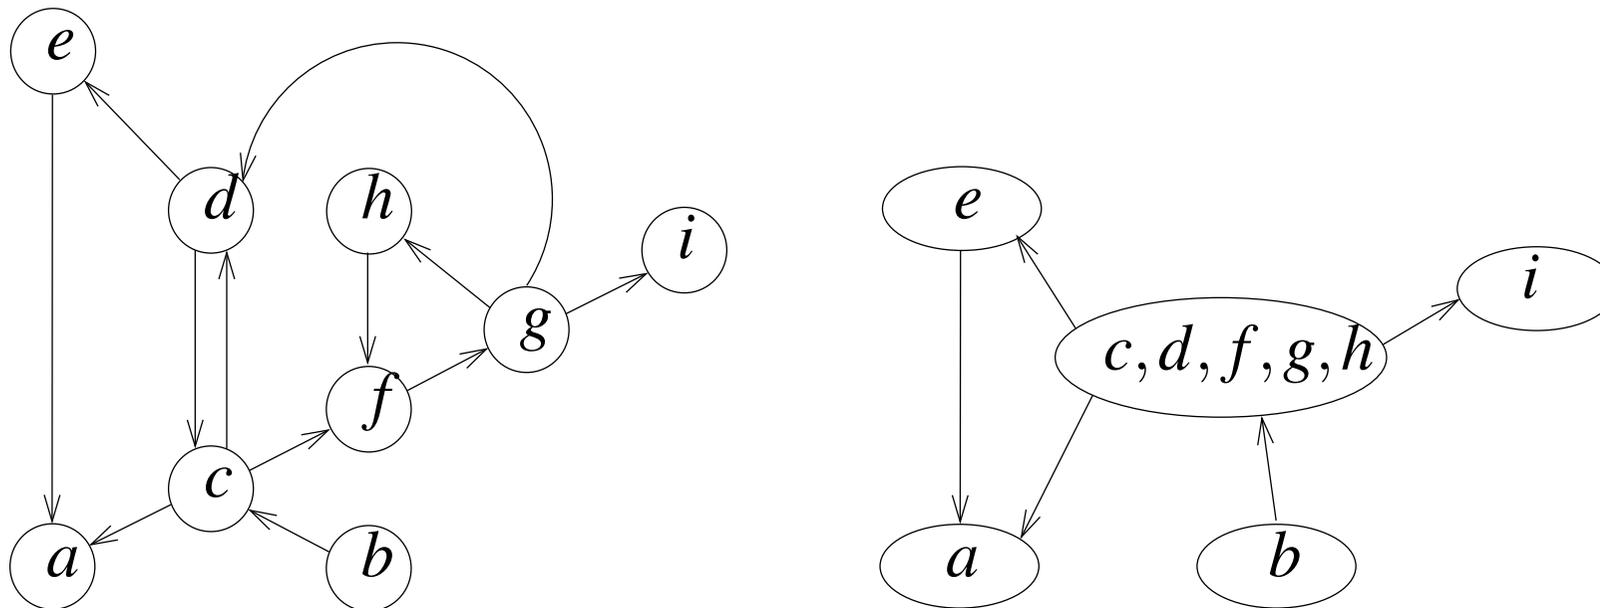
$E_c := E_c \cup \{e\}$

# Schrumpfgraph

$$G_c^s = (V^s, E_c^s)$$

Knoten: SCCs von  $G_c$ .

Kanten:  $(C, D) \in E_c^s \Leftrightarrow \exists (c, d) \in E_c : c \in C \wedge d \in D$



**Beobachtung:** Der Schrumpfgraph ist azyklisch

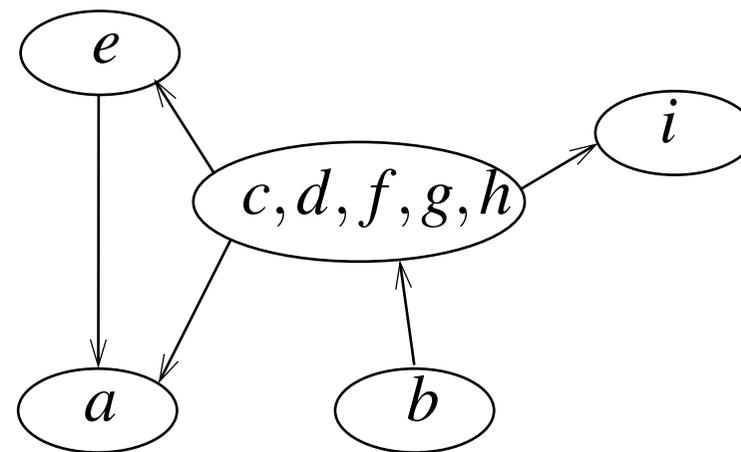
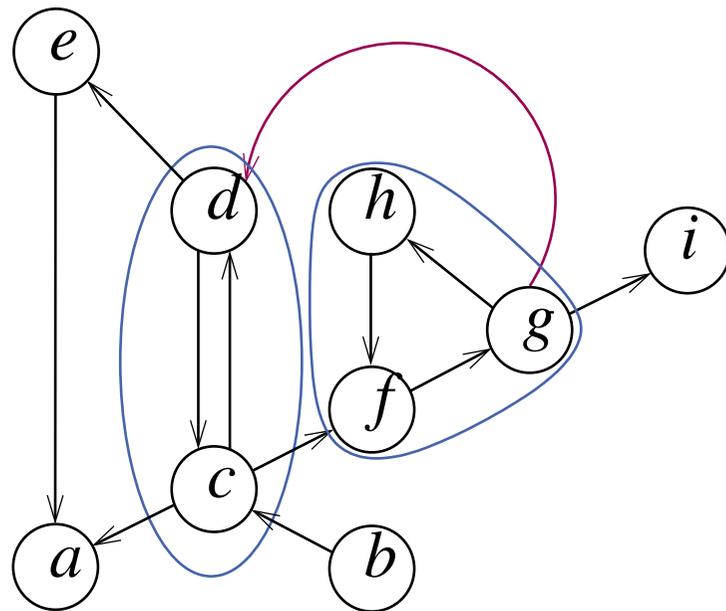
# Auswirkungen einer neuen Kante $e$ auf $G_c, G_c^s$

SCC-intern: Nichts ändert sich

zwischen zwei SCCs:

Kein Kreis: Neue Kante in  $G_c^s$

Kreisschluss: SCCs auf Kreis kollabieren.



## Konkreter: SCCs mittels DFS

[Cheriyān/Mehlhorn 96, Gabow 2000]

$V_c$  = markierte Knoten

$E_c$  = bisher explorierte Kanten

**Aktive Knoten**: markiert aber nicht finished.

SCCs von  $G_c$ :

nicht erreicht: Unmarkierte Knoten

offen: enthält aktive Knoten

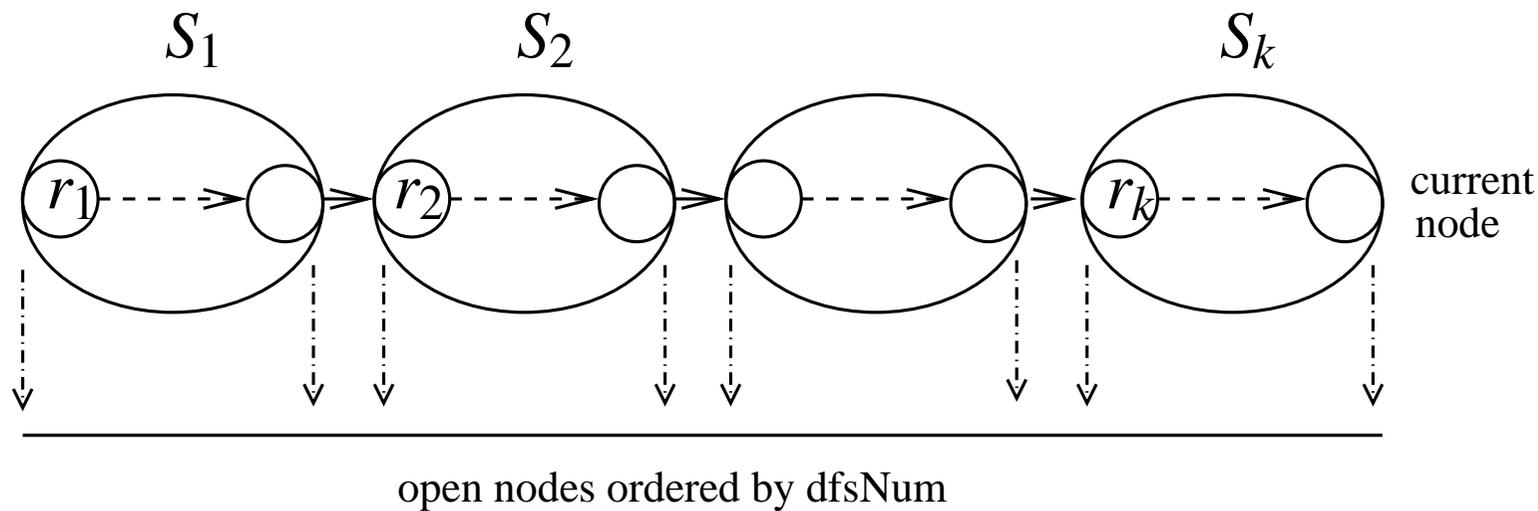
abgeschlossen: alle Knoten finished

**component[w]** gibt Repräsentanten einer SCC an.

Knoten von offenen (abgeschl.) Komponenten heißen offen (abgeschl.)

# Invarianten von $G_C$

1. Kanten von abgeschlossenen Knoten gehen zu abgeschlossenen Knoten
2. Offene Komponenten  $S_1, \dots, S_k$  bilden Pfad in  $G_C^S$ .
3. Repräsentanten partitionieren die offenen Komponenten bzgl. ihrer dfsNum.



**Lemma:** Abgeschlossene SCCs von  $G_c$  sind SCCs von  $G$

Betrachte abgeschlossenen Knoten  $v$

und beliebigen Knoten  $w$

in der SCC von  $v$  bzgl.  $G$ .

z.Z.:  $w$  ist abgeschlossen und

in der gleichen SCC von  $G_c$  wie  $v$ .

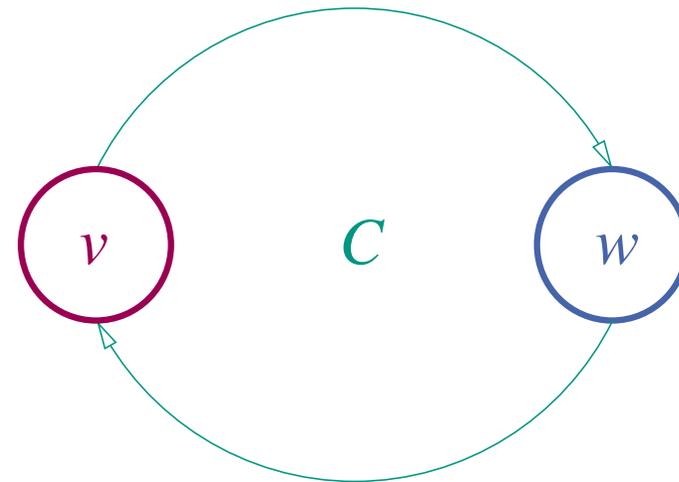
Betrachte Kreis  $C$  durch  $v, w$ .

Inv. 1: **Knoten** von  $C$  sind abgeschlossen.

Abgeschl. Knoten sind finished.

Kanten aus finished Knoten wurden exploriert.

Also sind alle **Kanten** von  $C$  in  $G_c$ .



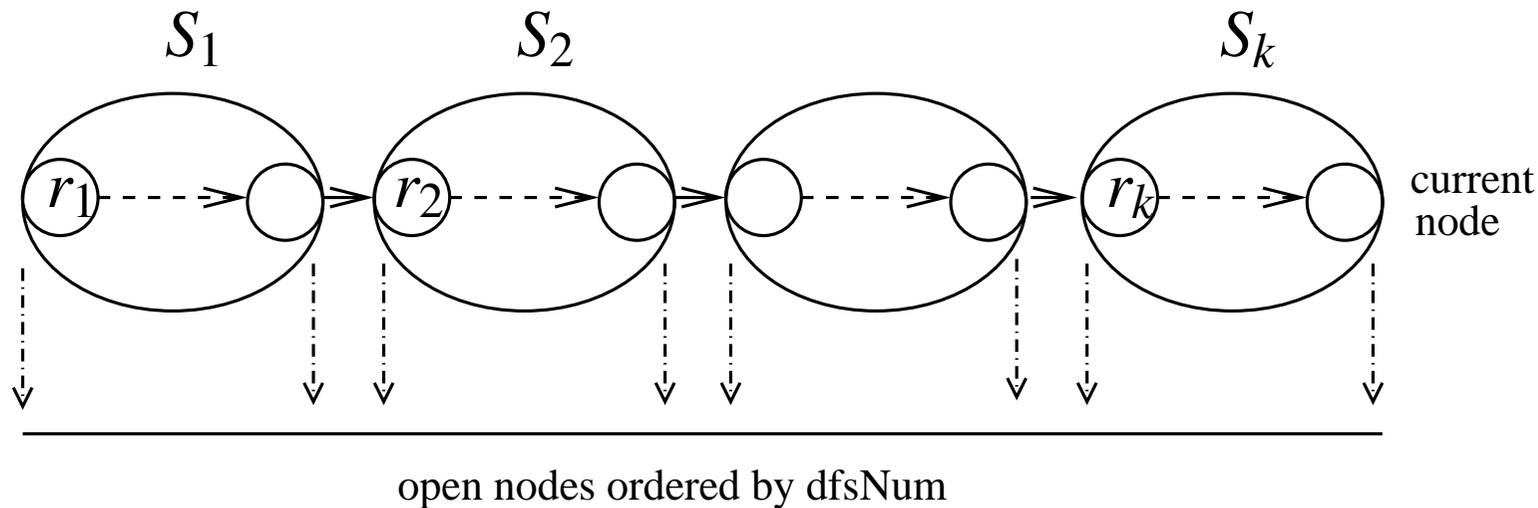
□

# Repräsentation offener Komponenten

Zwei Stapel aufsteigend sortiert nach dfsNum

**oReps**: Repräsentanten offener Komponenten

**oNodes**: Alle offenen Knoten



init

component : NodeArray **of** NodeId // SCC representatives

oReps= $\langle \rangle$  : Stack **of** NodeId // representatives of open SCCs

oNodes= $\langle \rangle$  : Stack **of** NodeId // all nodes in open SCCs

Alle Invarianten erfüllt.

(Weder offene noch geschlossene Knoten)

$\text{root}(s)$

$\text{oReps.push}(s)$

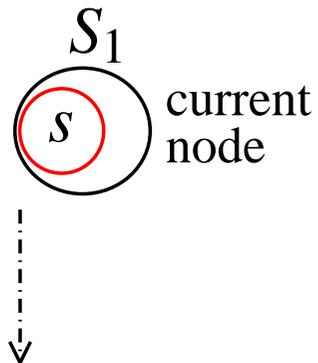
$\text{oNodes.push}(s)$

// new open

// component

$\{s\}$  ist die einzige offene Komponente.

Alle Invarianten bleiben gültig



open nodes ordered by dfsNum

traverseTreeEdge( $v, w$ )

oReps.push( $w$ )

oNodes.push( $w$ )

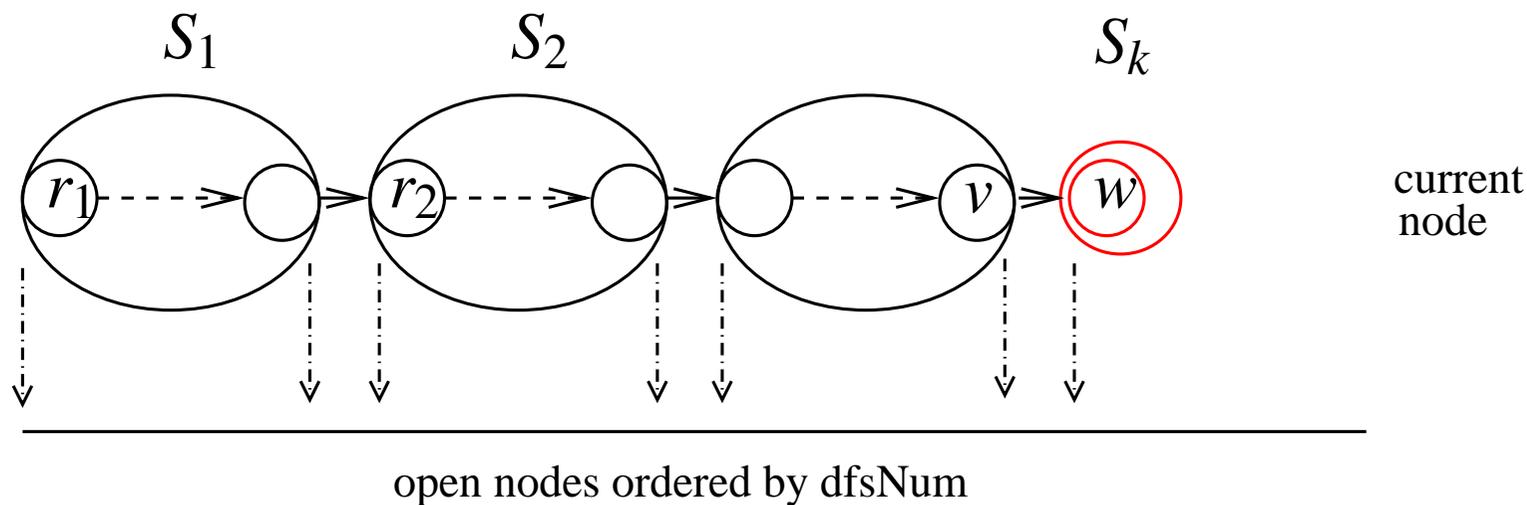
// new open

// component

$\{w\}$  ist neue offene Komponente.

$\text{dfsNum}(w) >$  alle anderen.

$\rightsquigarrow$  Alle Invarianten bleiben gültig



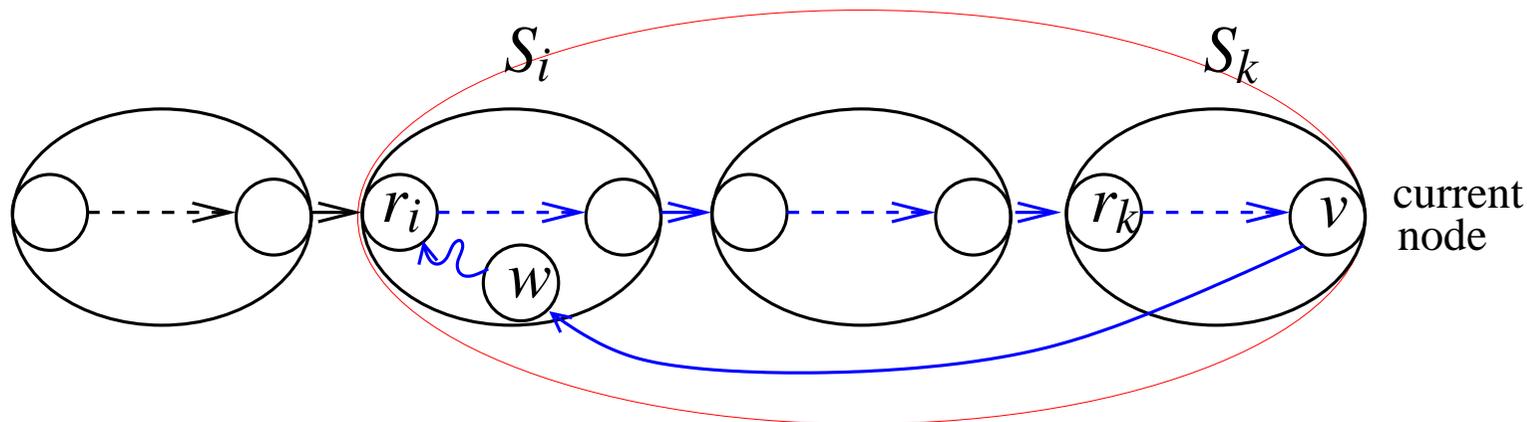
traverseNonTreeEdge( $v, w$ )

**if**  $w \in \text{oNodes}$  **then**

**while**  $w \prec \text{oReps.top}$  **do**  $\text{oReps.pop}$

$w \notin \text{oNodes} \rightsquigarrow w$  is abgeschlossen  $\overset{\text{Lemma}(*)}{\rightsquigarrow}$  Kante uninteressant

$w \in \text{oNodes}$ : kollabiere offene SCCs auf **Kreis**



backtrack( $u, v$ )

**if**  $v = \text{oReps.top}$  **then**

oReps.pop

// close

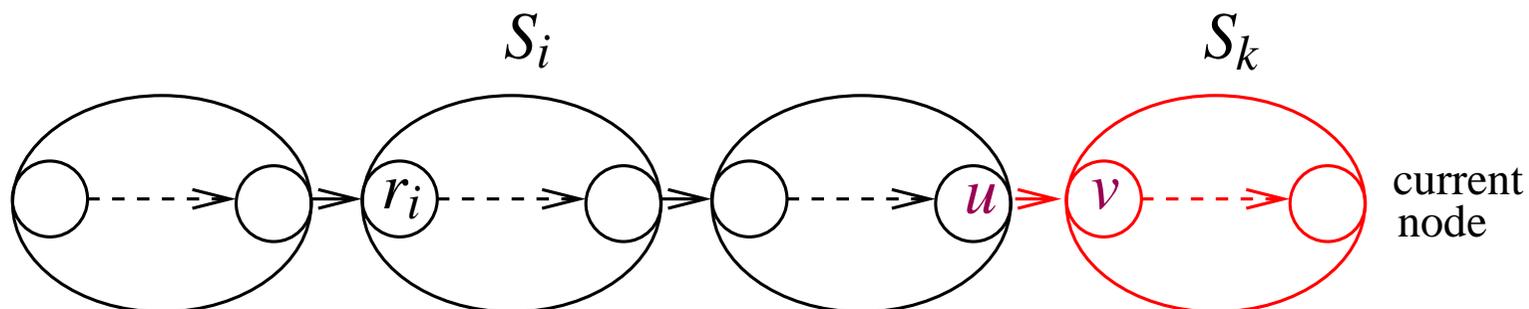
**repeat**

// component

$w := \text{oNodes.pop}$

component[ $w$ ] :=  $v$

**until**  $w = v$



z.Z. Invarianten bleiben erhalten...

backtrack( $u, v$ )

**if**  $v = \text{oReps.top}$  **then**

oReps.pop

**repeat**

$w := \text{oNodes.pop}$

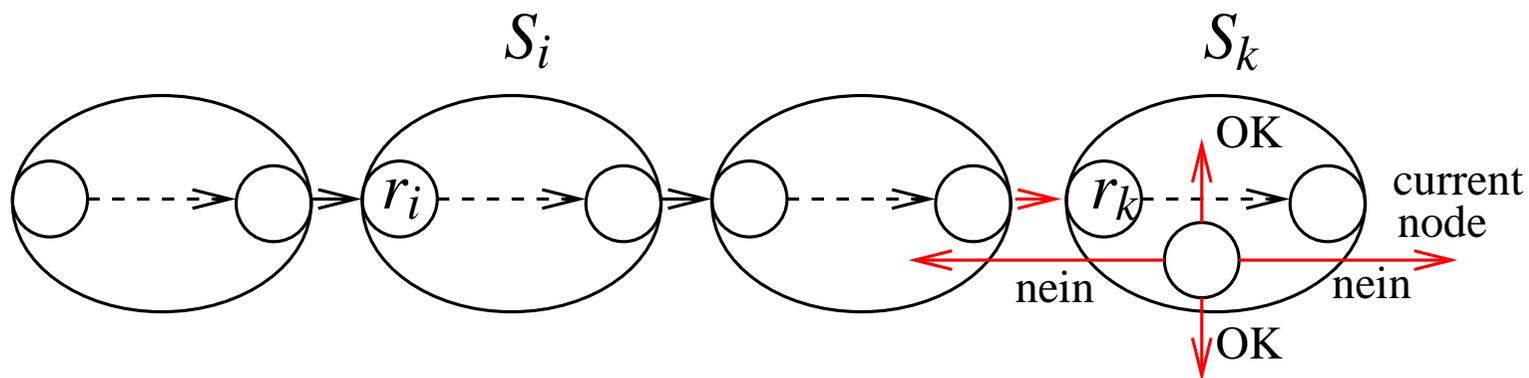
component[ $w$ ] :=  $v$

**until**  $w = v$

// close

// component

**Inv. 1:** Kanten von abgeschlossenen Knoten gehen zu abgeschlossenen Knoten.



backtrack( $u, v$ )

**if**  $v = \text{oReps.top}$  **then**

oReps.pop

**repeat**

$w := \text{oNodes.pop}$

component[ $w$ ] :=  $v$

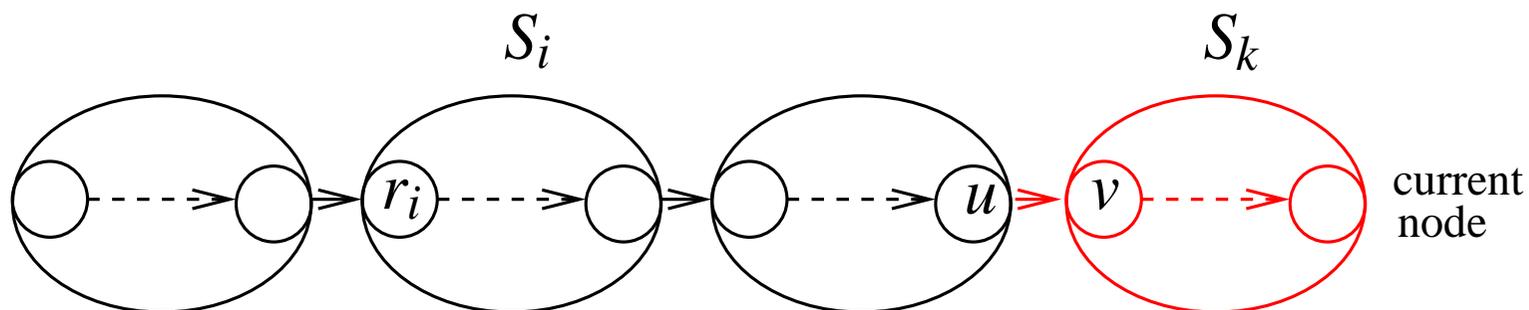
**until**  $w = v$

// close

// component

**Inv. 2:** Offene Komponenten  $S_1, \dots, S_k$  bilden Pfad in  $G_c^s$

OK. ( $S_k$  wird ggf. entfernt)

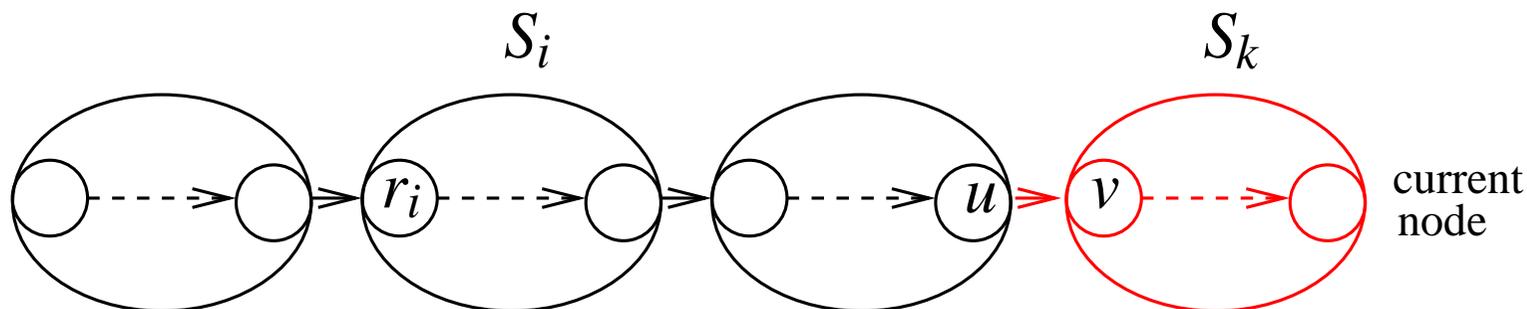


```

backtrack( $u, v$ )
  if  $v = \text{oReps.top}$  then
    oReps.pop // close
  repeat // component
     $w := \text{oNodes.pop}$ 
    component[ $w$ ] :=  $v$ 
  until  $w = v$ 
    
```

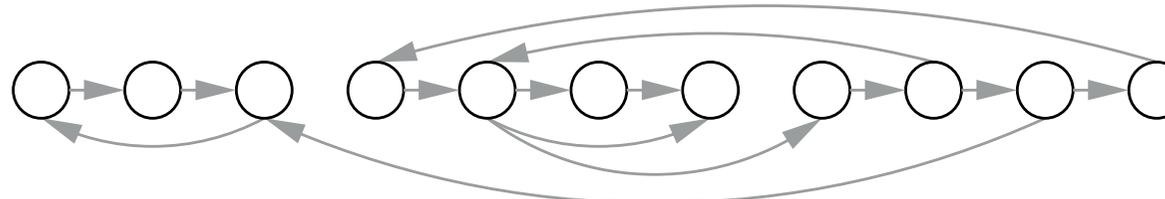
**Inv. 3:** Repräsentanten partitionieren die offenen Komponenten bzgl. ihrer dfsNum.

OK. ( $S_k$  wird ggf. entfernt)

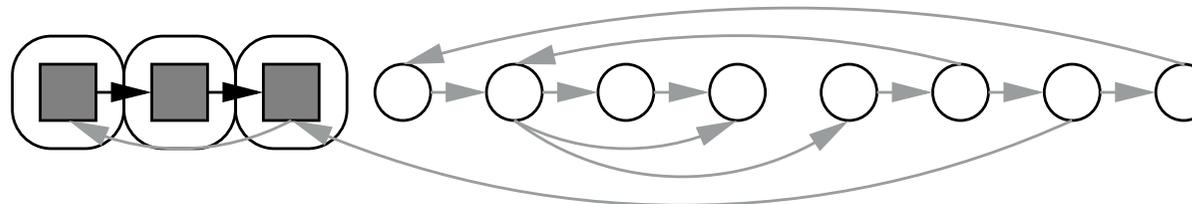


# Beispiel

a b c d e f g h i j k



root(a) traverse(a,b) traverse(b,c)



unmarked    marked    finished



nonrepresentative node



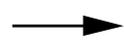
representative node



nontraversed edge



closed SCC

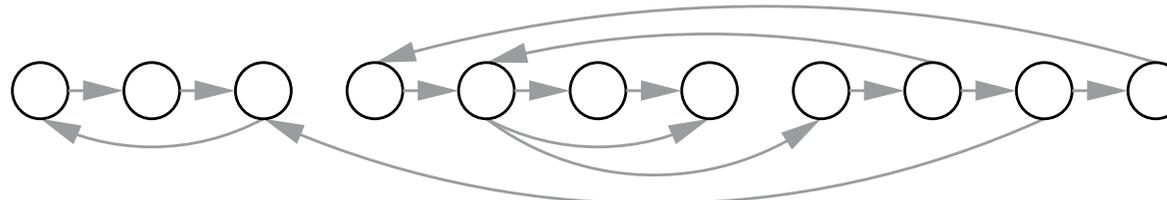


traversed edge

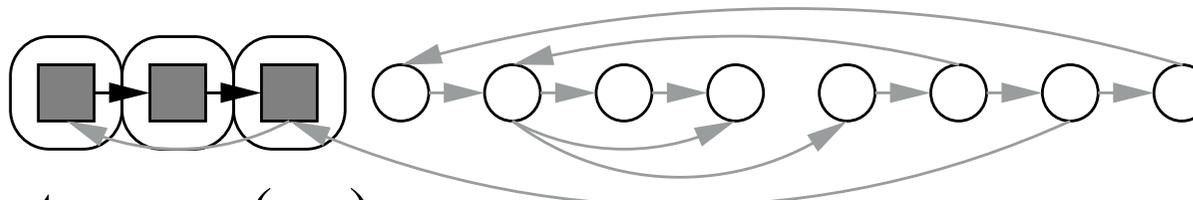


open SCC

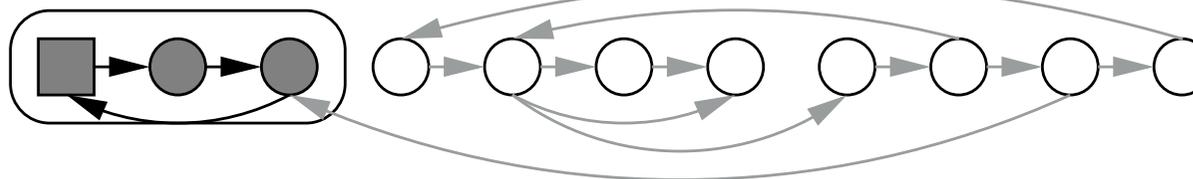
a b c d e f g h i j k



root(a) traverse(a,b) traverse(b,c)



traverse(c,a)



unmarked    marked    finished



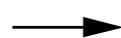
nonrepresentative node



representative node



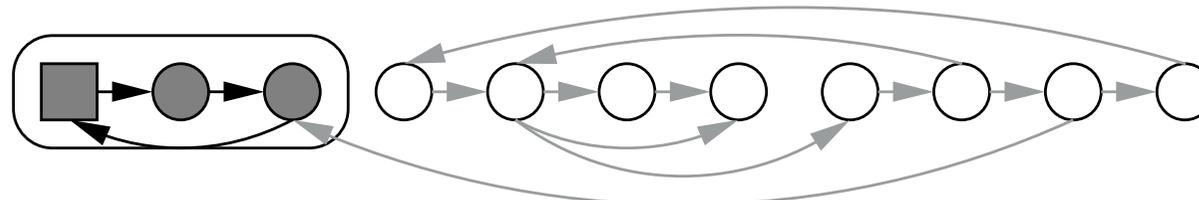
nontraversed edge



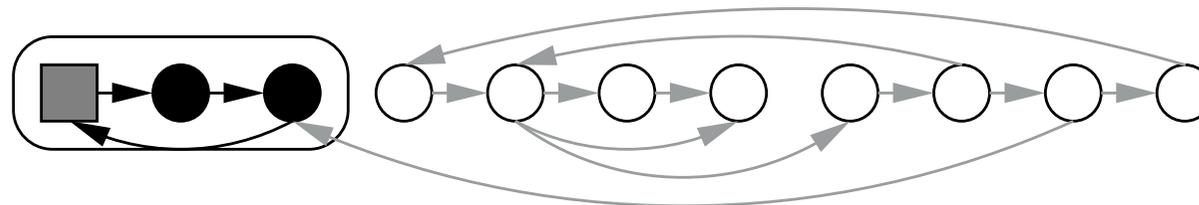
traversed edge



a b c d e f g h i j k



backtrack(b,c) backtrack(a,b)



unmarked marked finished



nonrepresentative node



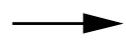
representative node



nontraversed edge



closed SCC

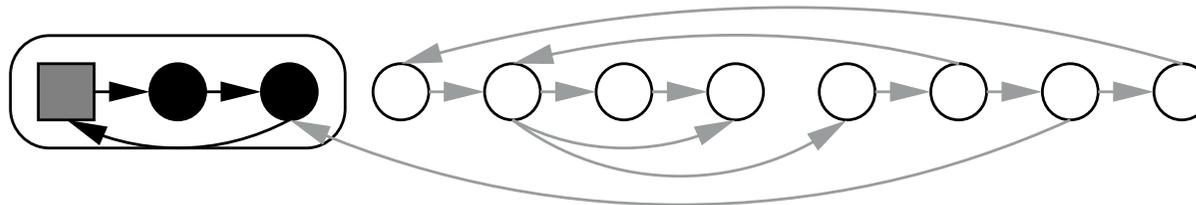


traversed edge

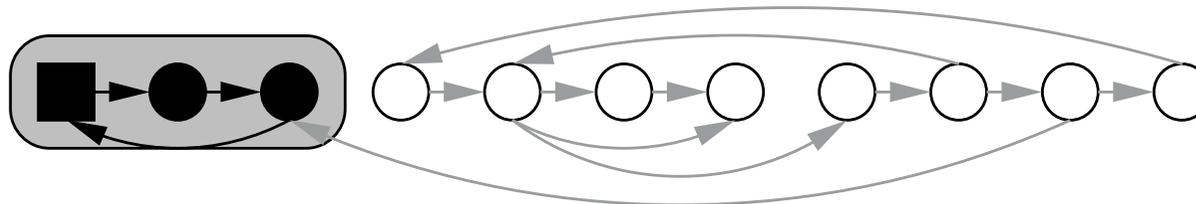


open SCC

a b c d e f g h i j k



backtrack(a,a)



unmarked    marked    finished



nonrepresentative node



representative node



nontraversed edge



closed SCC

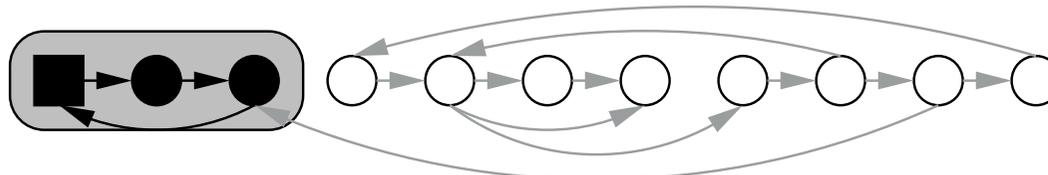


traversed edge

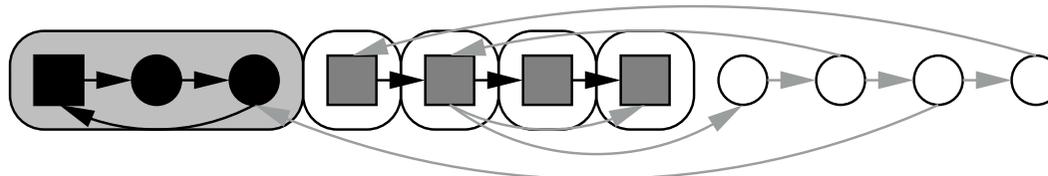


open SCC

a b c d e f g h i j k



root(d) traverse(d,e) traverse(e,f) traverse(f,g)



unmarked marked finished



nonrepresentative node



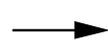
representative node



nontraversed edge



closed SCC

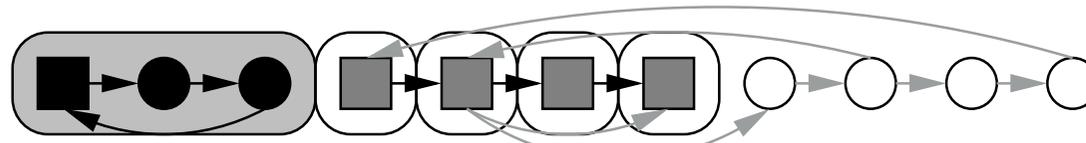


traversed edge

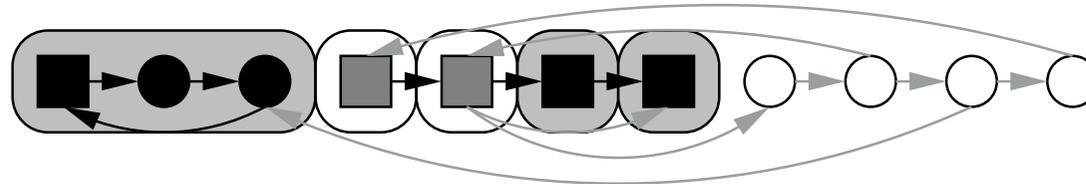


open SCC

a b c d e f g h i j k



backtrack(f,g) backtrack(e,f)



unmarked marked finished



nonrepresentative node

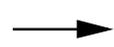


representative node



nontraversed edge

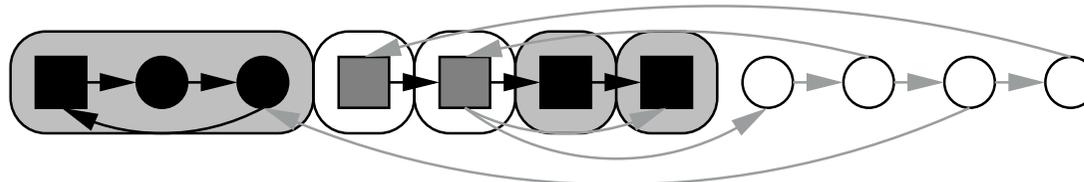
closed SCC



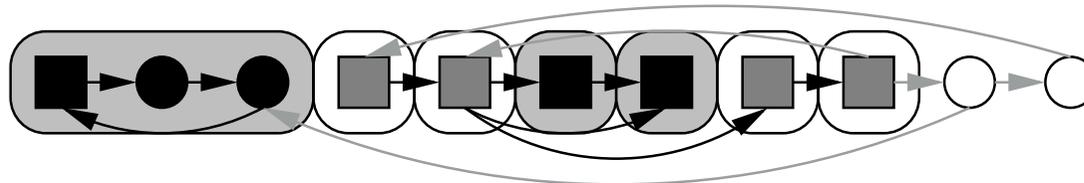
traversed edge

open SCC

a b c d e f g h i j k



traverse(e,g) traverse(e,h) traverse(h,i)



unmarked marked finished



nonrepresentative node



representative node



nontraversed edge



closed SCC

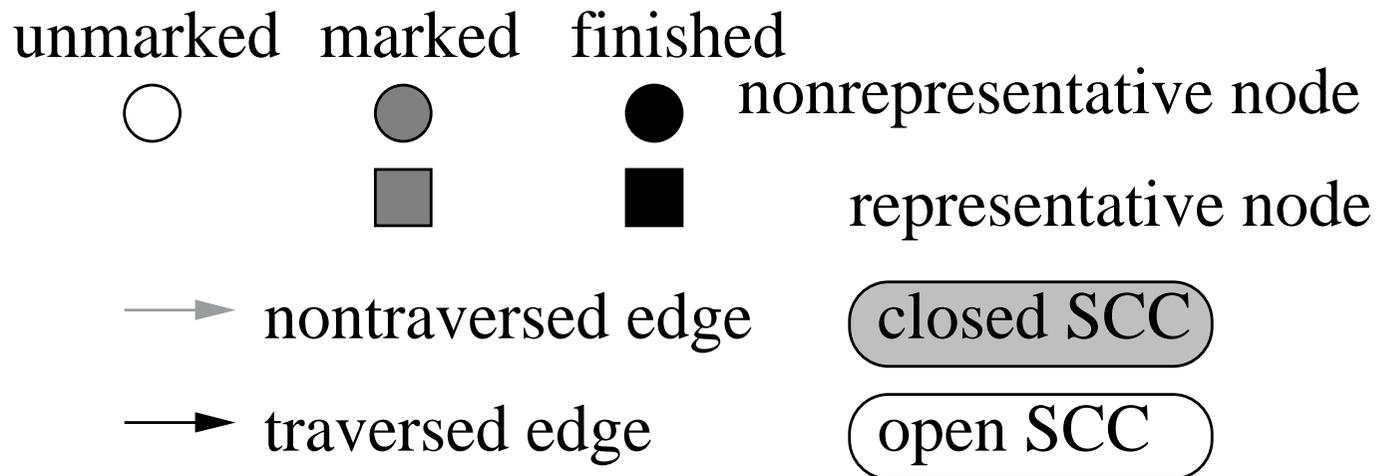
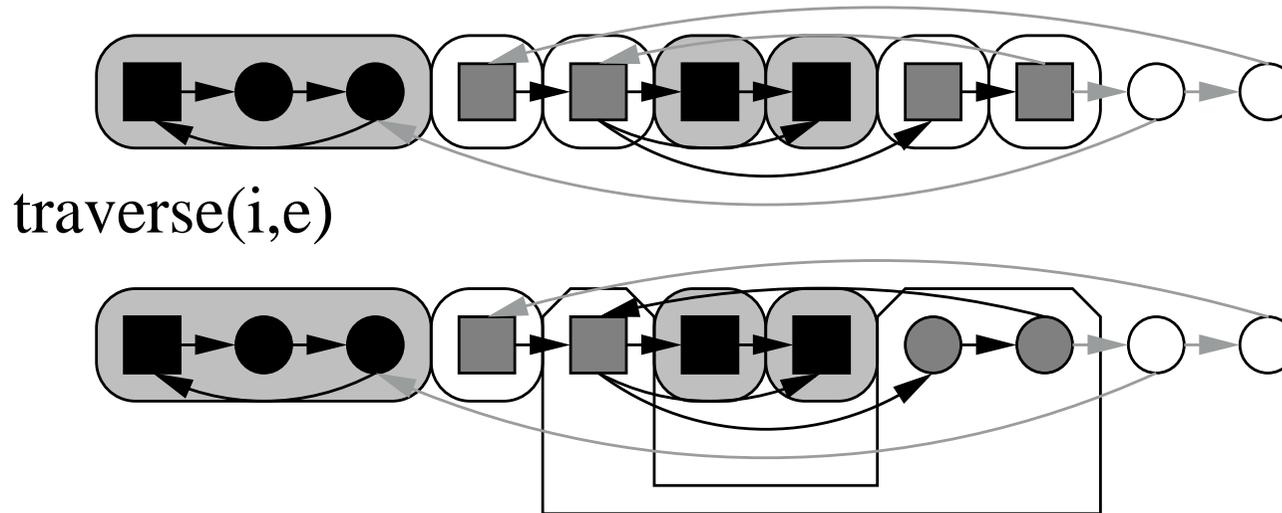


traversed edge

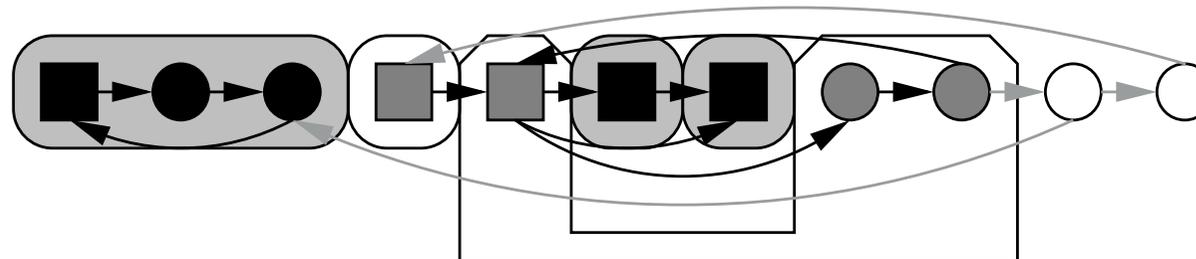


open SCC

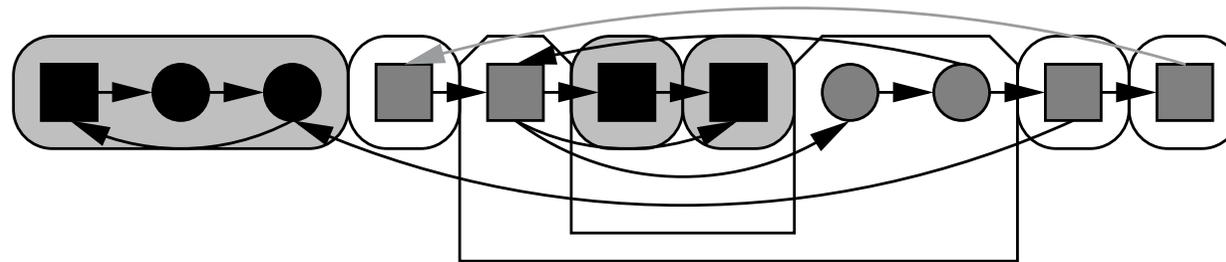
a b c d e f g h i j k



a b c d e f g h i j k



traverse(i,j)    traverse(j,c)    traverse(j,k)



unmarked    marked    finished



nonrepresentative node



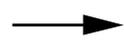
representative node



nontraversed edge



closed SCC

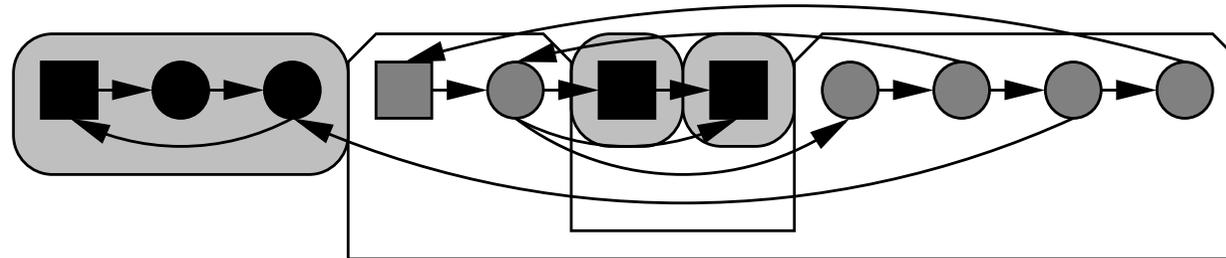
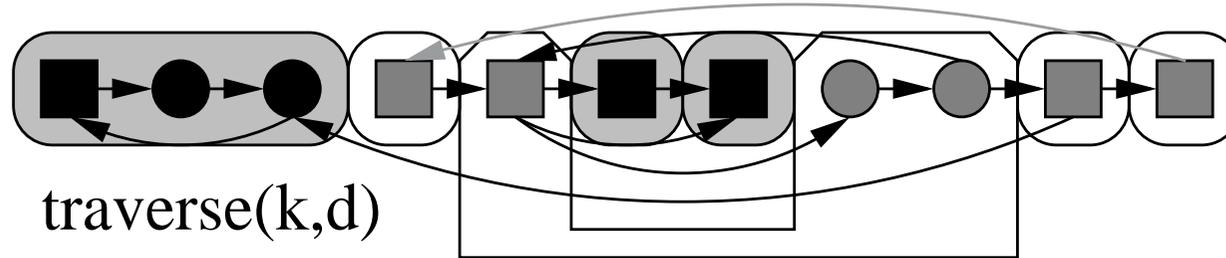


traversed edge



open SCC

a b c d e f g h i j k



unmarked    marked    finished



nonrepresentative node



representative node



nontraversed edge



closed SCC

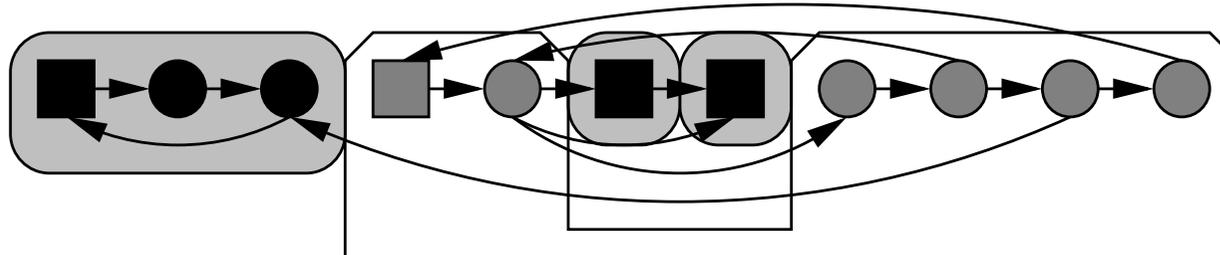


traversed edge

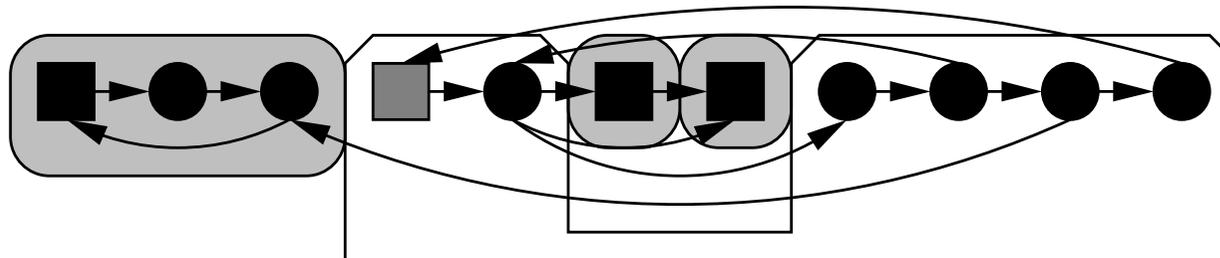


open SCC

a b c d e f g h i j k



backtrack(j,k) backtrack(i,j) backtrack(h,i)  
backtrack(e,h) backtrack(d,e)



unmarked marked finished



nonrepresentative node



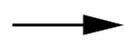
representative node



nontraversed edge



closed SCC

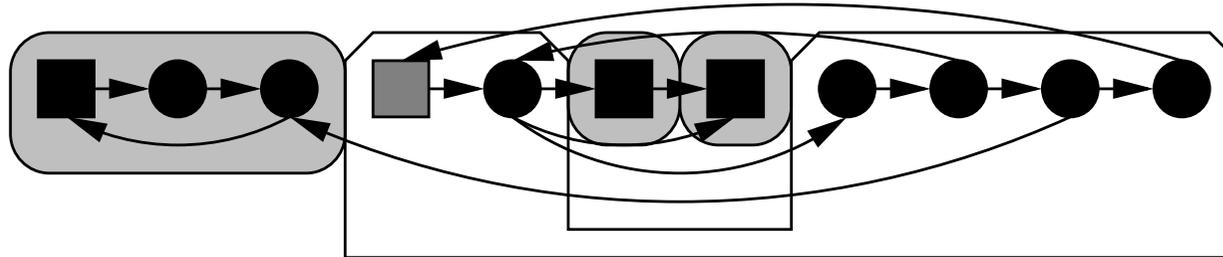


traversed edge

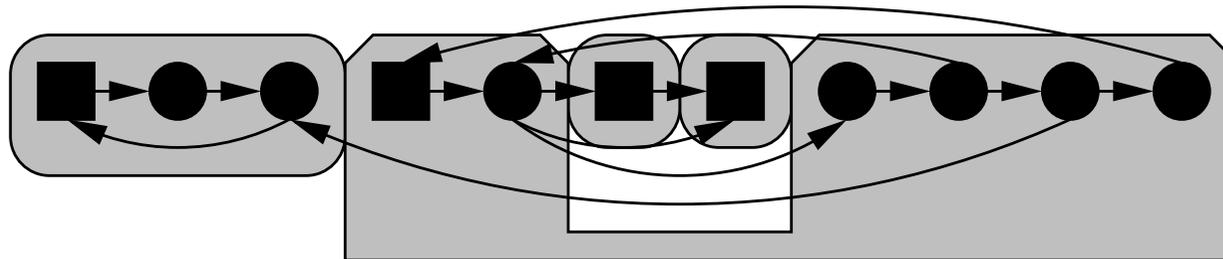


open SCC

a b c d e f g h i j k



backtrack(d,d)



unmarked    marked    finished



nonrepresentative node



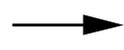
representative node



nontraversed edge



closed SCC



traversed edge



open SCC

## Zusammenfassung: SCC Berechnung

- Einfache Instantiierung des DFS-Musters
- Nichttrivialer Korrektheitsbeweis
- Laufzeit  $O(m + n)$ : (Jeweils max.  $n$  push/pop Operationen)
- Ein einziger Durchlauf

Implementierungsdetails:

Mehlhorn, Näher, Sanders

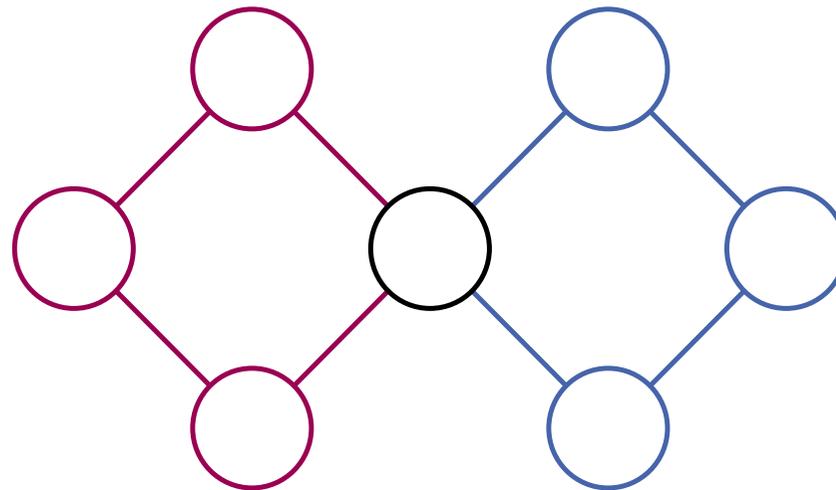
Engineering DFS-Based Graph Algorithms

[arxiv.org/abs/1703.10023](https://arxiv.org/abs/1703.10023)

## 2-zusammenhängende Komponenten (ungerichtet)

Bei entfernen eines Knotens bleibt die Komponente  
zusammenhängend.

(Partitionierung der Kanten)



Geht in Zeit  $O(m + n)$  mit Algorithmus ähnlich zu SCC-Algorithmus

# Mehr DFS-basierte Linearzeitalgorithmen

- 3-zusammenhängende Komponenten
- Planaritätstest
- Einbettung planarer Graphen

# 5 Maximum Flows and Matchings

[mit Kurt Mehlhorn, Rob van Stee]

Folien auf Englisch

Literatur:

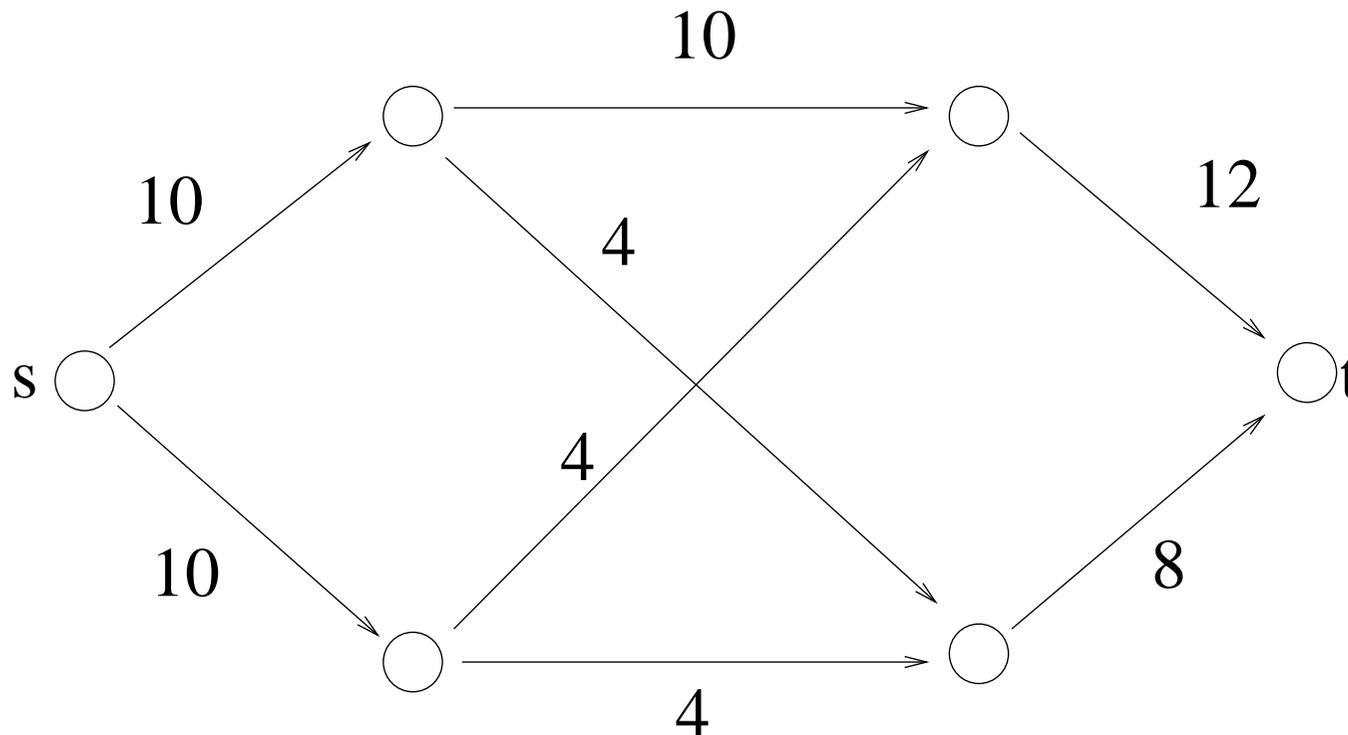
[Mehlhorn / Näher, The LEDA Platform of Combinatorial and Geometric Computing, Cambridge University Press, 1999]

[http://www.mpi-inf.mpg.de/~mehlhorn/ftp/LEDABook/Graph\\_alg.ps](http://www.mpi-inf.mpg.de/~mehlhorn/ftp/LEDABook/Graph_alg.ps)

[Ahuja, Magnanti, Orlin, Network Flows, Prentice Hall, 1993]

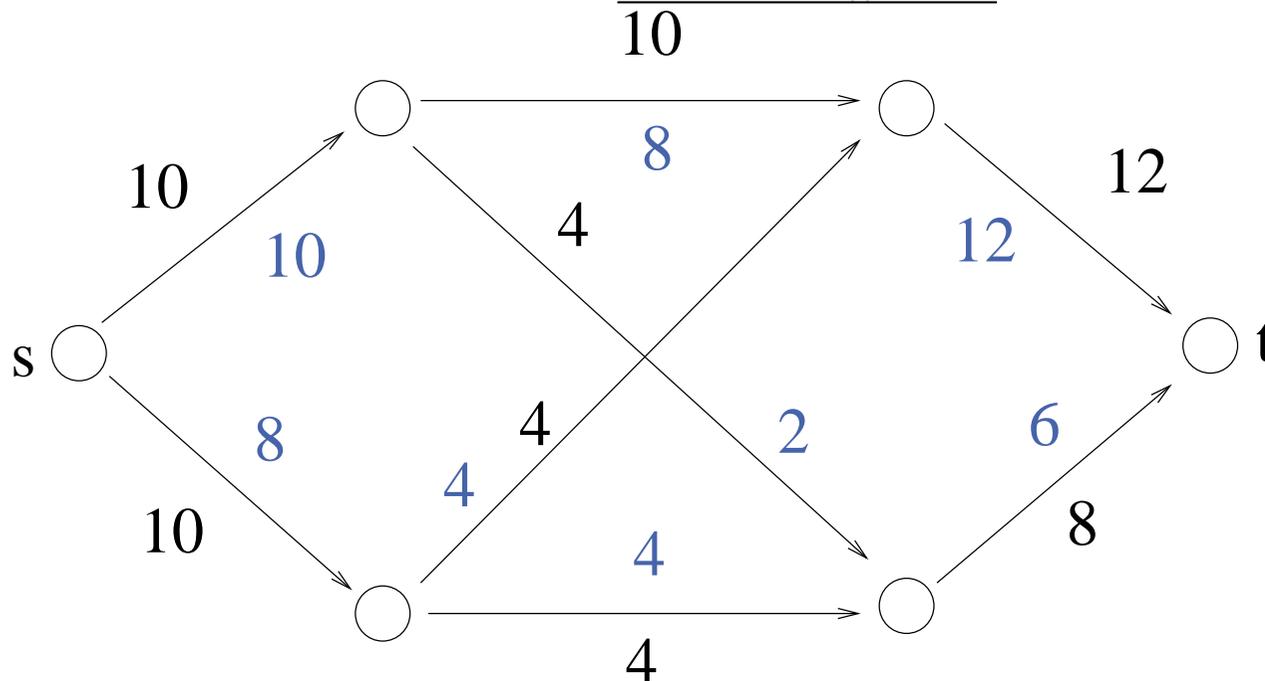
## Definitions: Network

- Network = directed weighted graph with  
source node  $s$  and sink node  $t$
- $s$  has no incoming edges,  $t$  has no outgoing edges
- Weight  $c_e$  of an edge  $e$  = capacity of  $e$  (nonnegative!)



## Definitions: Flows

- Flow = function  $f_e$  on the edges,  $0 \leq f_e \leq c_e \forall e$   
 $\forall v \in V \setminus \{s, t\}$ : total incoming flow = total outgoing flow
- Value of a flow  $\mathbf{val}(f) =$  total outgoing flow from  $s =$   
total flow going into  $t$
- Goal: find a flow with maximum value

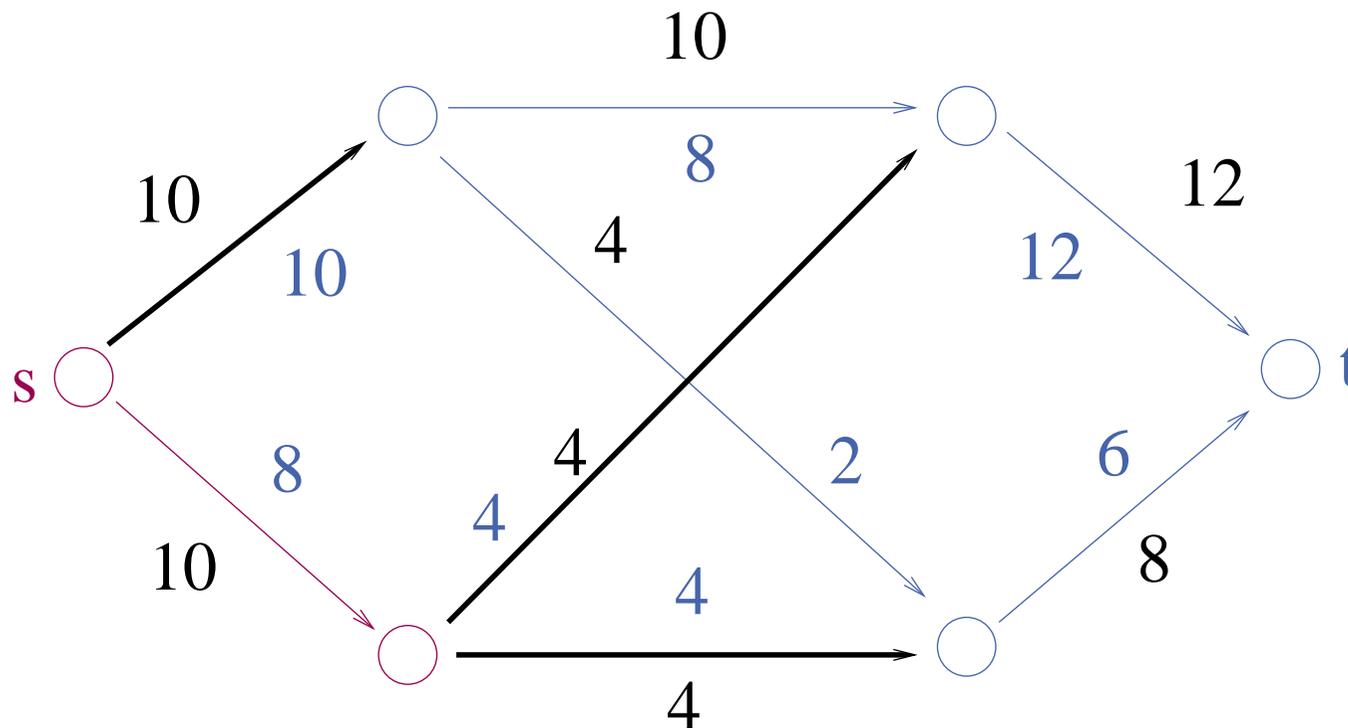


## Definitions: (Minimum) $s$ - $t$ Cuts

An  $s$ - $t$  cut is partition of  $V$  into  $S$  and  $T$  with  $s \in S$  and  $t \in T$ .

The **capacity** of this cut is:

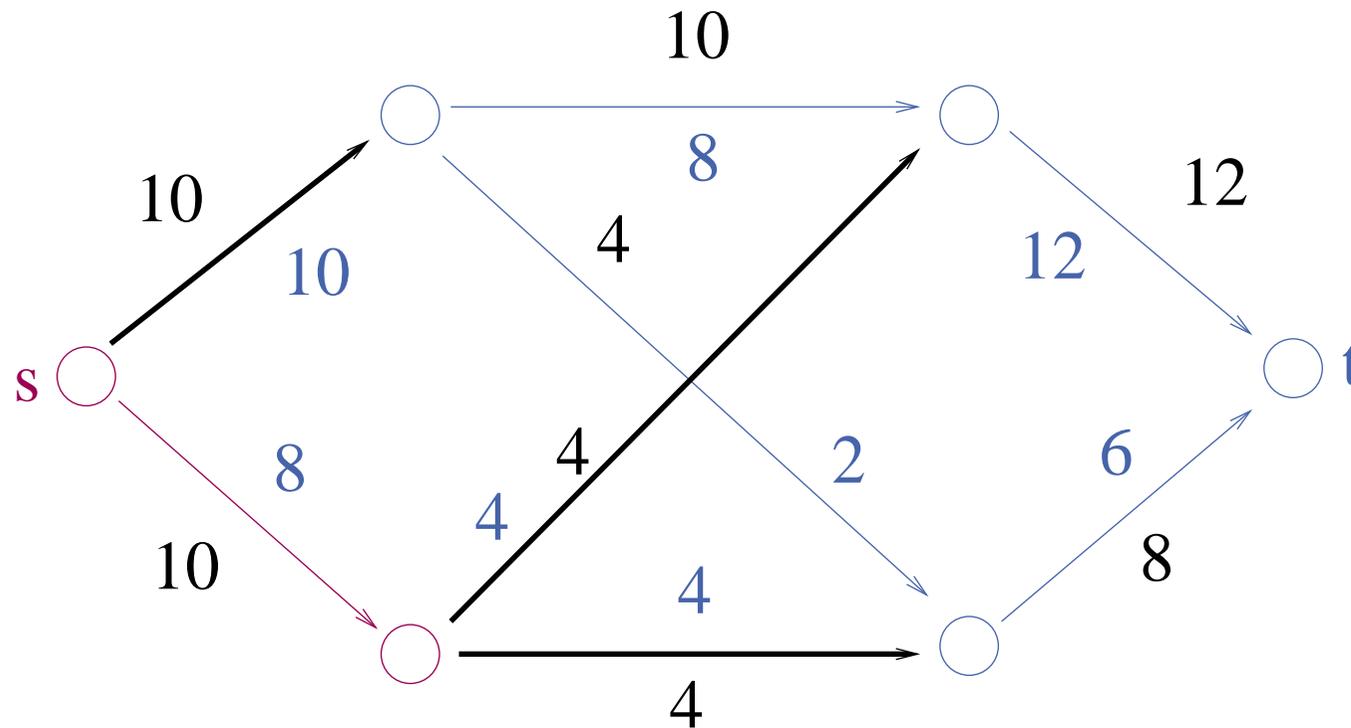
$$\sum \{c_{(u,v)} : u \in S, v \in T\}$$



# Duality Between Flows and Cuts

**Theorem:**[Elias/Feinstein/Shannon, Ford/Fulkerson 1956]

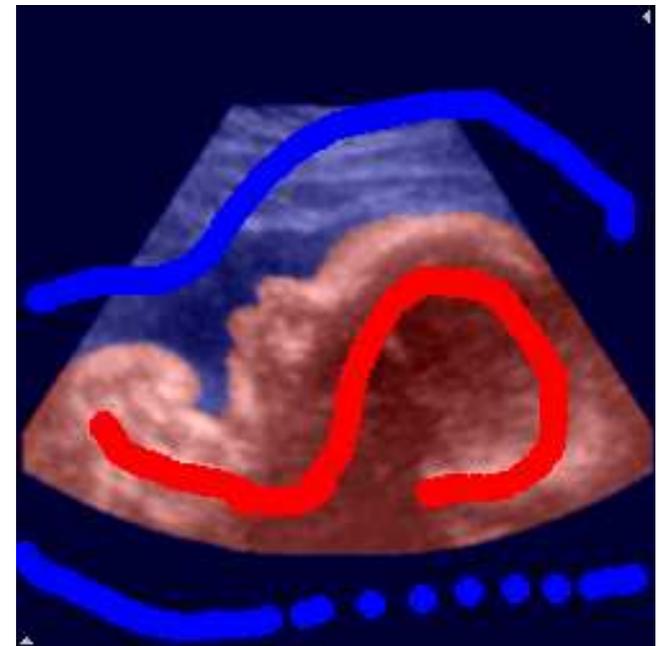
Value of an  $s$ - $t$  max-flow = minimum capacity of an  $s$ - $t$  cut.



**Proof:** later

# Applications

- Oil pipes
- Traffic flows on highways
- Image Processing** <http://vision.csd.uwo.ca/maxflow-data>
  - segmentation
  - stereo processing
  - multiview reconstruction
  - surface fitting
- disk/machine/tanker **scheduling**
- matrix **rounding**
- ...



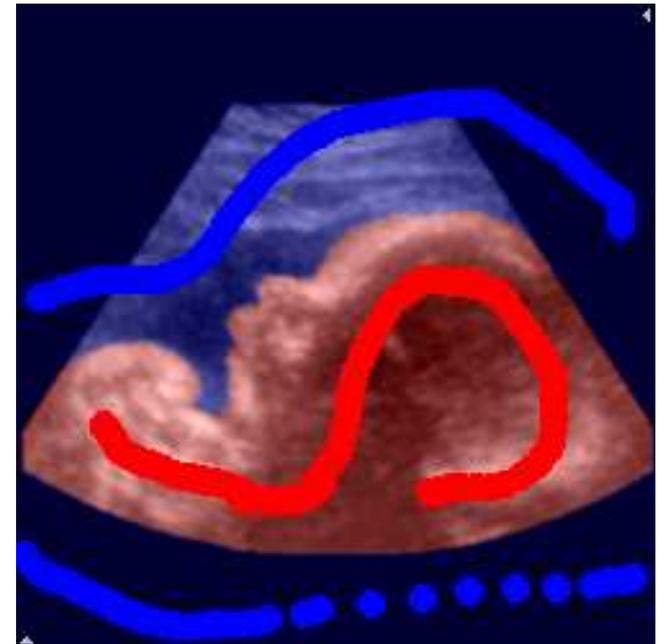
# Current Research Challenge: AI versus Optimal Algorithms

Many image processing applications are currently taken over by **deep convolutional neural networks**.

- + Often better results
- + No ad-hoc definitions of  $s$ ,  $t$ ,  $c$
- “Optimality” is thrown over board
- Lots of **training examples** needed

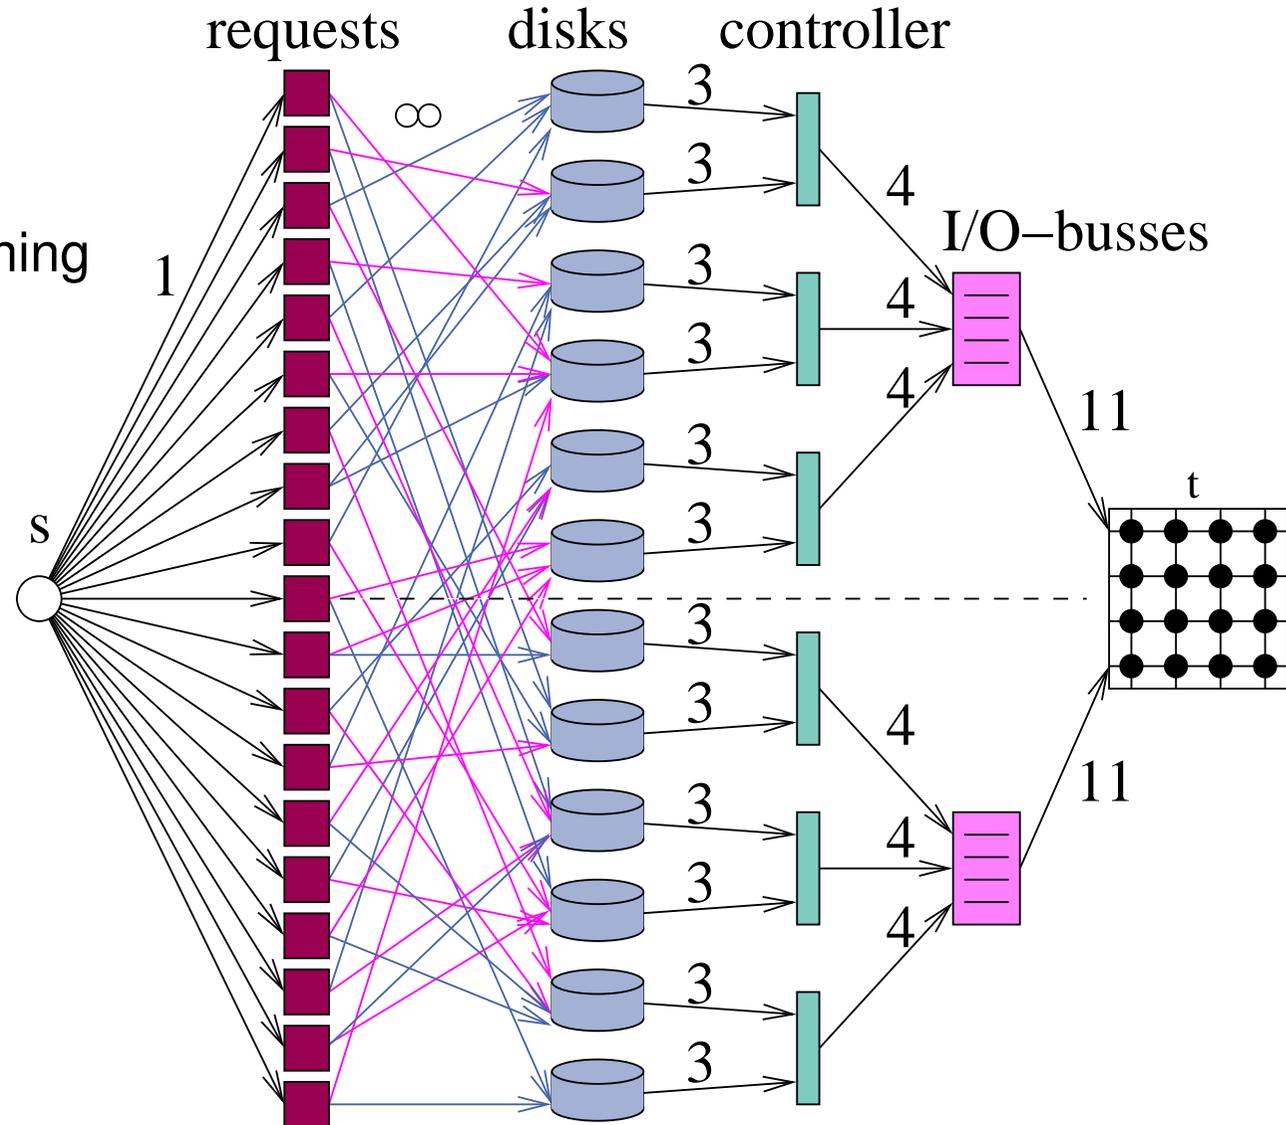
Is there a **middle way**?

Learn  $s$ ,  $t$ ,  $c$  then optimize?



# Applications in our Group

- multicasting using network coding
- balanced  $k$  partitioning
- disk scheduling



## Option 1: linear programming

- Flow variables  $x_e$  for each edge  $e$
- Flow on each edge is at most its capacity
- Incoming flow at each vertex = outgoing flow from this vertex
- Maximize outgoing flow from starting vertex

We can do better!

# Algorithms 1956–now

Year	Author	Running time	
1956	Ford-Fulkerson	$O(mnU)$	
1969	Edmonds-Karp	$O(m^2n)$	
1970	Dinic	$O(mn^2)$	
1973	Dinic-Gabow	$O(mn \log U)$	$n =$ number of nodes
1974	Karzanov	$O(n^3)$	$m =$ number of arcs
1977	Cherkassky	$O(n^2 \sqrt{m})$	$U =$ largest capacity
1980	Galil-Naamad	$O(mn \log^2 n)$	
1983	Sleator-Tarjan	$O(mn \log n)$	

Year	Author	Running time
1986	Goldberg-Tarjan	$O(mn \log(n^2/m))$
1987	Ahuja-Orlin	$O(mn + n^2 \log U)$
1987	Ahuja-Orlin-Tarjan	$O(mn \log(2 + n\sqrt{\log U}/m))$
1990	Cheriyon-Hagerup-Mehlhorn	$O(n^3 / \log n)$
1990	Alon	$O(mn + n^{8/3} \log n)$
1992	King-Rao-Tarjan	$O(mn + n^{2+\epsilon})$
1993	Philipps-Westbrook	$O(mn \log n / \log \frac{m}{n} + n^2 \log^{2+\epsilon} n)$
1994	King-Rao-Tarjan	$O(mn \log n / \log \frac{m}{n \log n})$ if $m \geq 2n \log n$
1997	Goldberg-Rao	$O(\min\{m^{1/2}, n^{2/3}\} m \log(n^2/m) \log U)$
2014	Lee-Sidford	$O(m\sqrt{n} \log^2 U)$

## Augmenting Paths (Rough Idea)

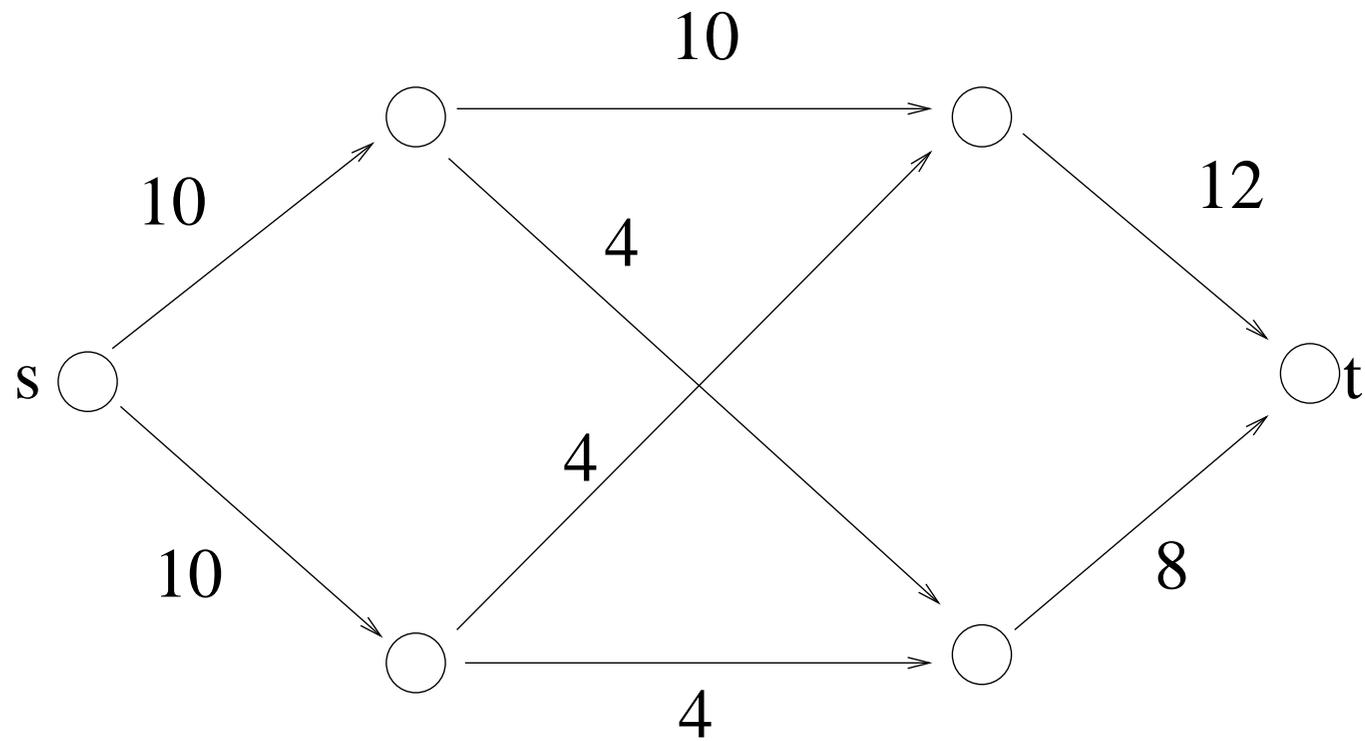
Find a path from  $s$  to  $t$  such that each edge has some **spare capacity**

On this path, **saturate** the edge with the smallest spare capacity

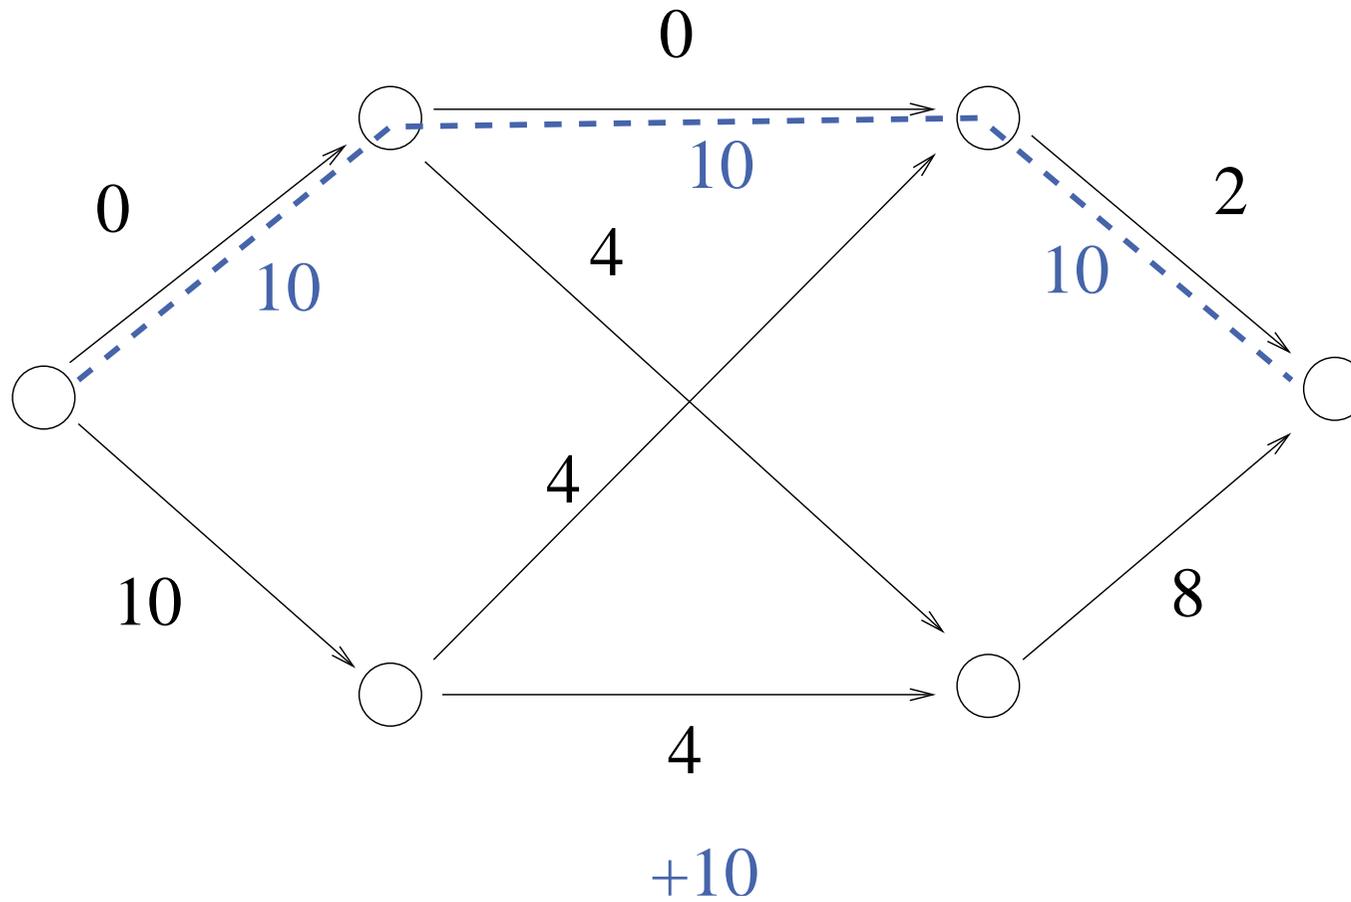
**Adjust capacities** for all edges (create **residual graph**) and repeat

A typical **greedy algorithm**

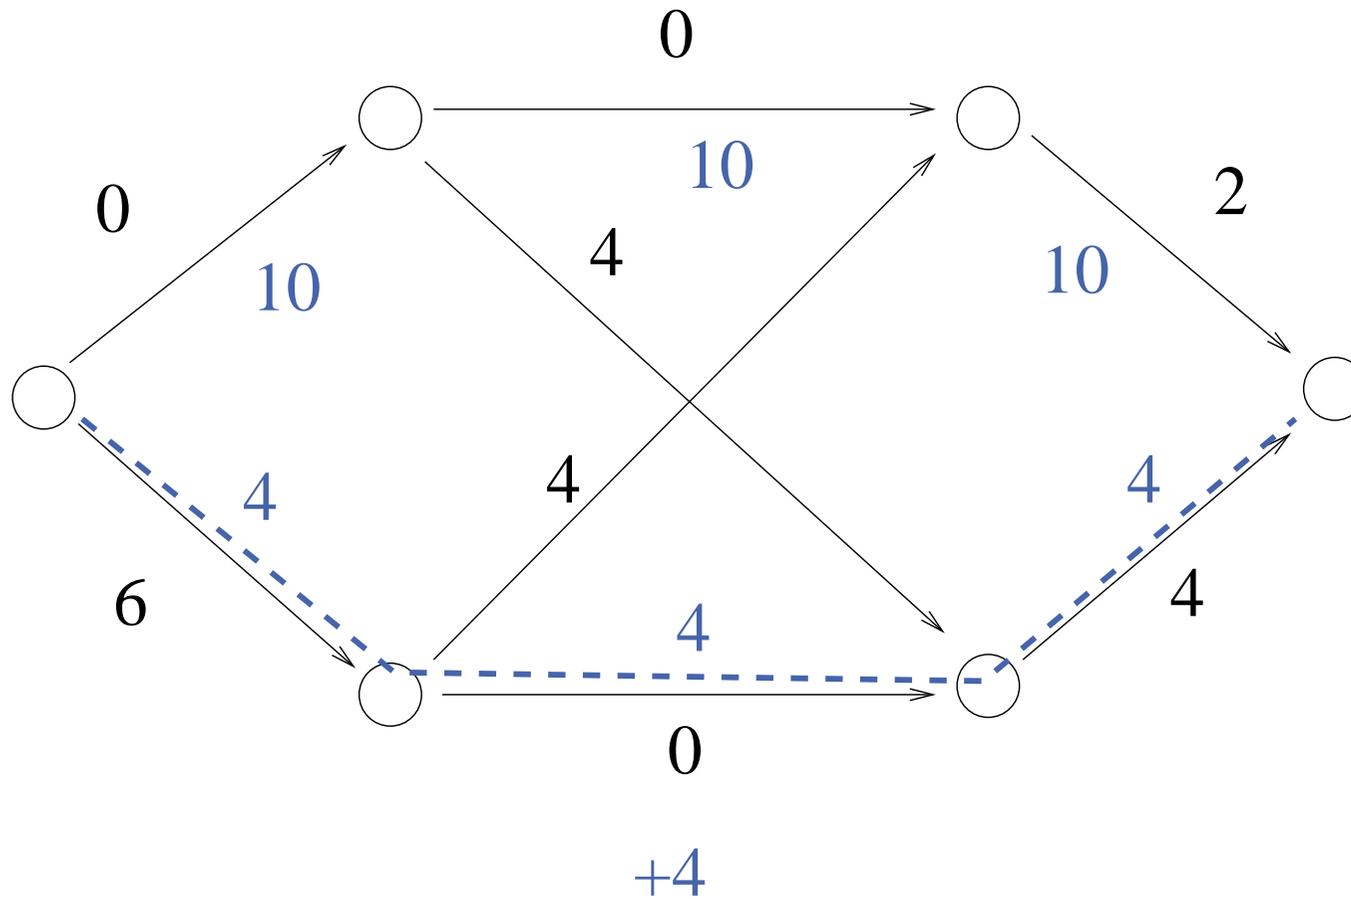
# Example



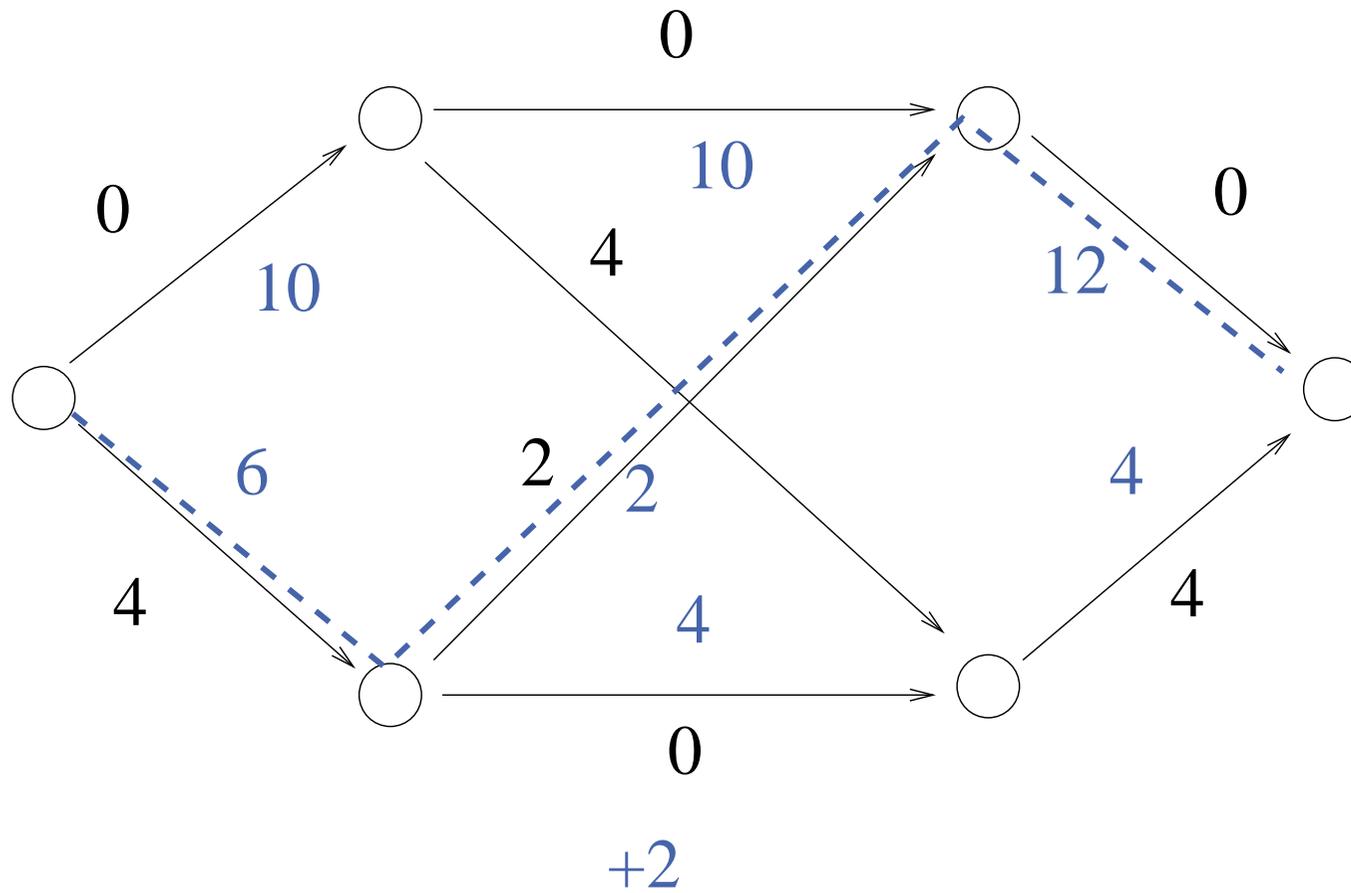
# Example



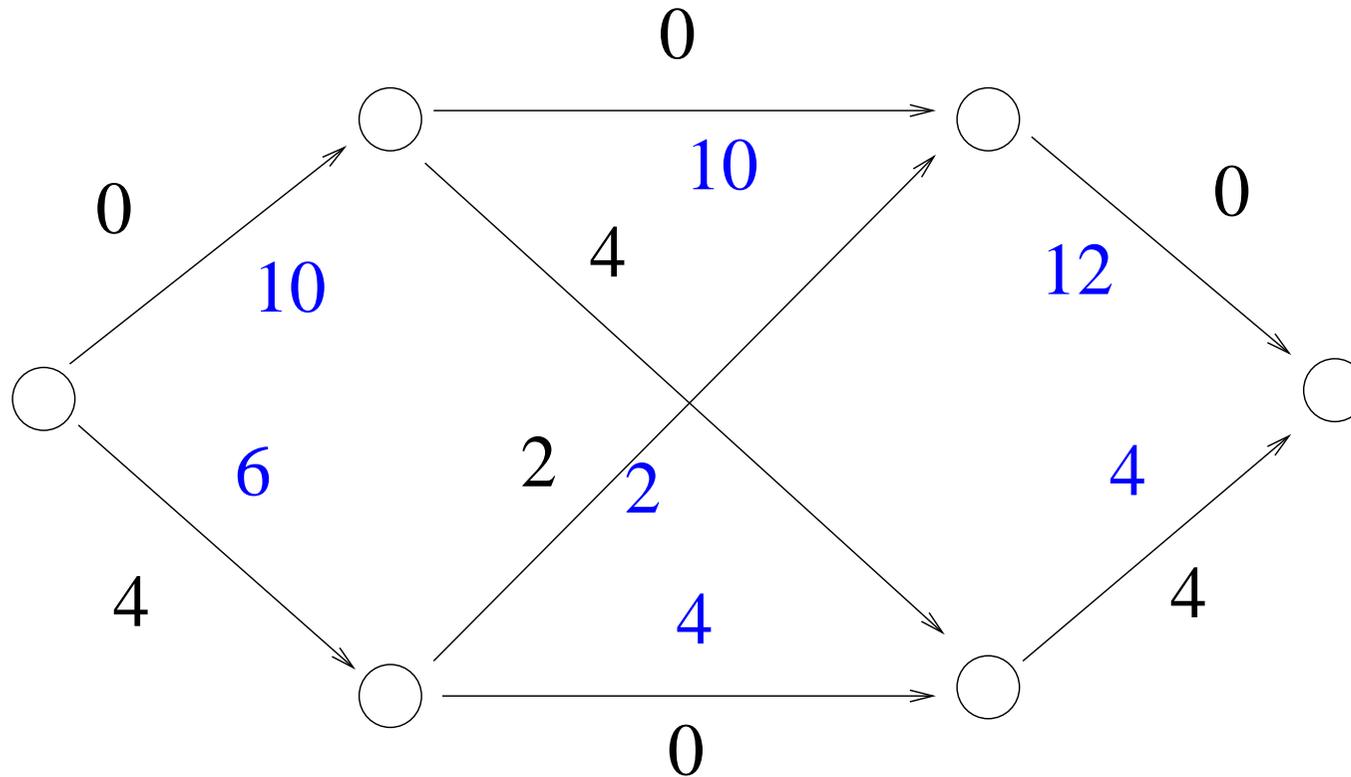
# Example



# Example

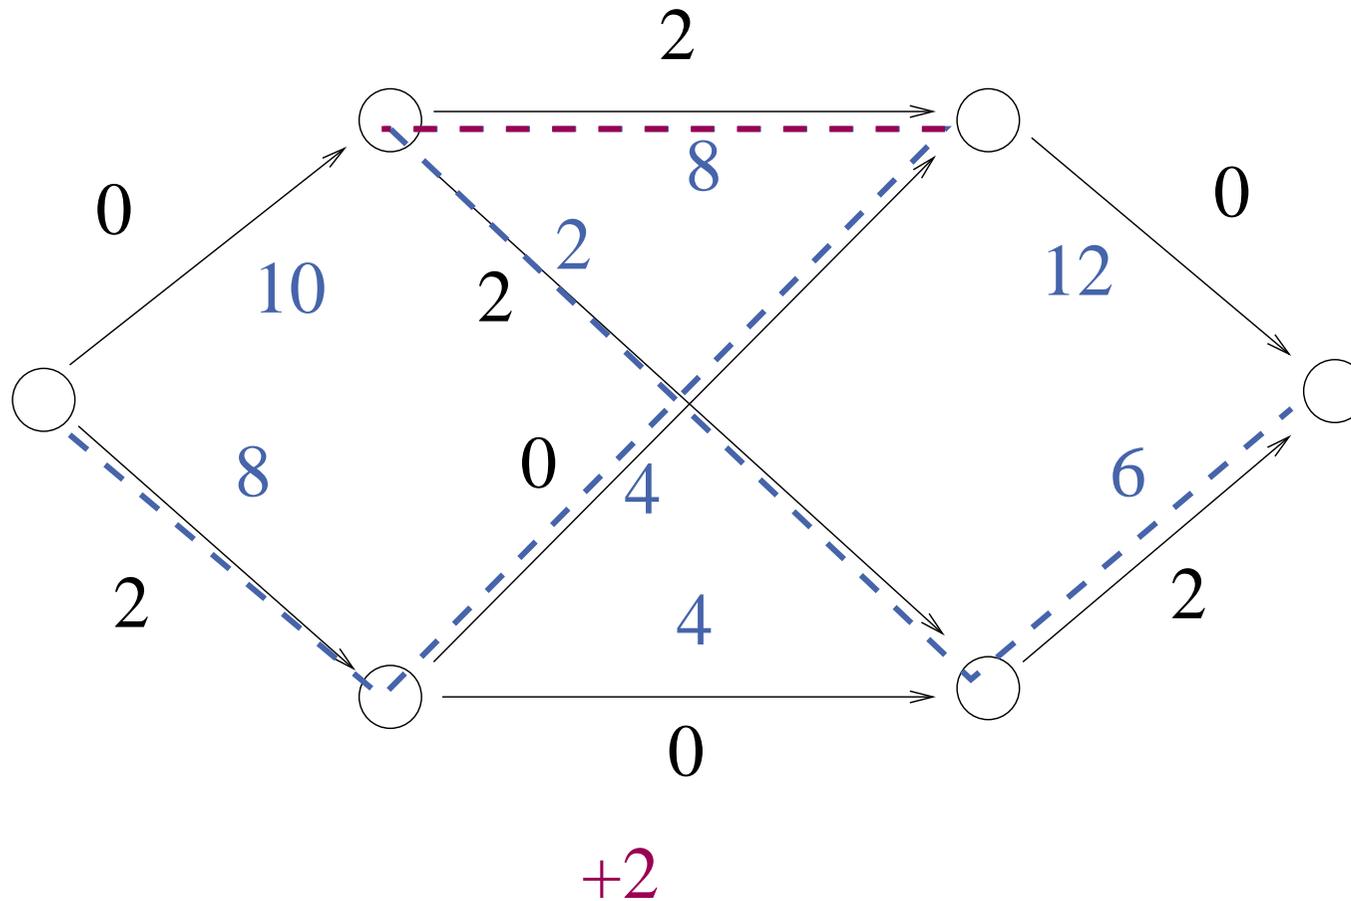


# Example



are we done?

# Example

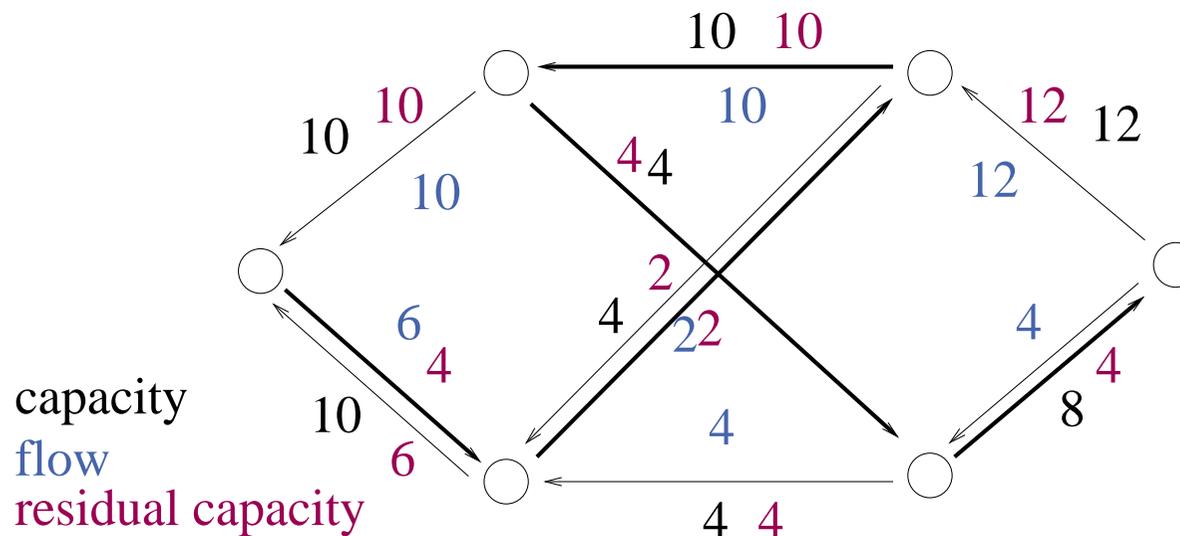


# Residual Graph

Given, network  $G = (V, E, c)$ , flow  $f$

Residual graph  $G_f = (V, E_f, c^f)$ . For each  $e \in E$  we have

$$\begin{cases} e \in E_f \text{ with } c_e^f = c_e - f(e) & \text{if } f(e) < c(e) \\ e^{\text{rev}} \in E_f \text{ with } c_{e^{\text{rev}}}^f = f(e) & \text{if } f(e) > 0 \end{cases}$$



## Augmenting Paths

Find a path  $p$  from  $s$  to  $t$  such that each edge  $e$  has nonzero residual capacity  $c_e^f$

$$\Delta f := \min_{e \in p} c_e^f$$

**foreach**  $(u, v) \in p$  **do**

**if**  $(u, v) \in E$  **then**  $f_{(u,v)} + = \Delta f$

**else**  $f_{(v,u)} - = \Delta f$

# Ford Fulkerson Algorithm

**Function**  $\text{FFMaxFlow}(G = (V, E), s, t, c : E \rightarrow \mathbb{N}) : E \rightarrow \mathbb{N}$

$f := 0$

**while**  $\exists$  path  $p = (s, \dots, t)$  in  $G_f$  **do**

    augment  $f$  along  $p$

**return**  $f$

time  $O(m \cdot \text{val}(f))$

## Ford Fulkerson – Correctness

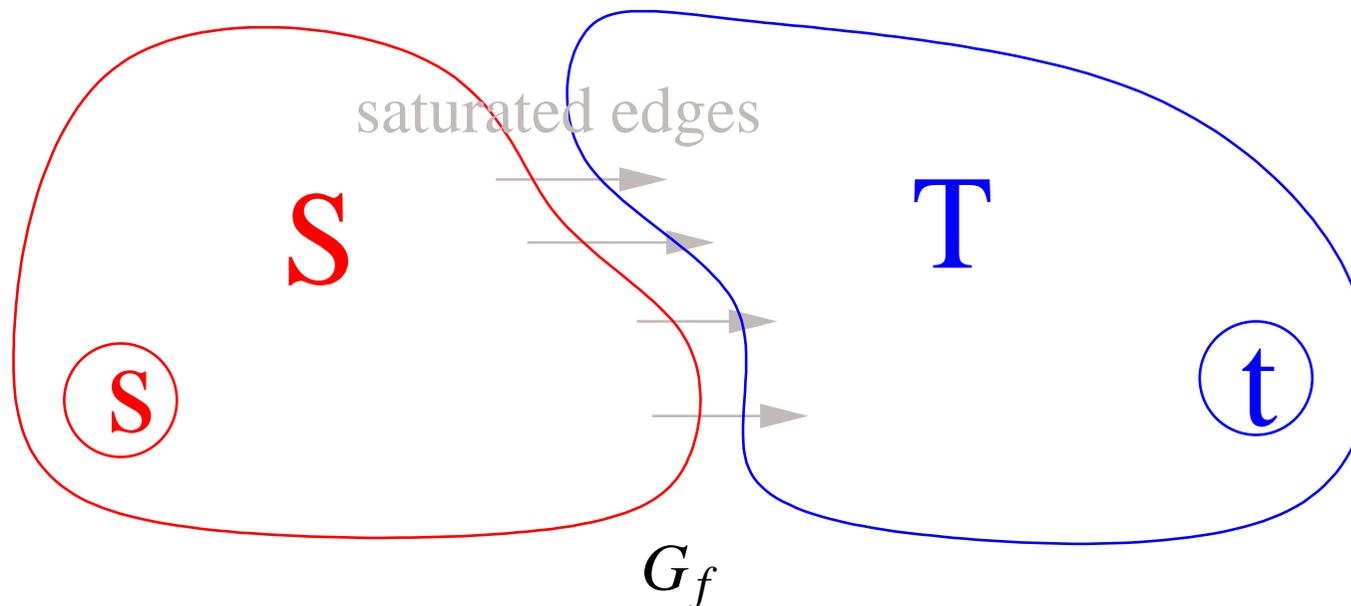
“Clearly” FF computes a feasible flow  $f$ . (Invariant)

Todo: flow value is **maximal**

At termination: no augmenting paths in  $G_f$  left.

Consider cut  $(S, T := V \setminus S)$  with

$S := \{v \in V : v \text{ reachable from } s \text{ in } G_f\}$



## A Basic Observations

**Lemma 1:** For any cut  $(S, T)$ :

$$\mathbf{val}(f) = \overbrace{\sum_{e \in E \cap S \times T} f_e}^{S \rightarrow T \text{ edges}} - \overbrace{\sum_{e \in E \cap T \times S} f_e}^{T \rightarrow S \text{ edges}} .$$

## Ford Fulkerson – Correctness

**Todo:**  $\text{val}(f)$  is **maximal** when no augmenting paths in  $G_f$  left.

Consider cut  $(S, T := V \setminus S)$  with

$S := \{v \in V : v \text{ reachable from } s \text{ in } G_f\}$ .

**Observation:**  $\forall (u, v) \in E \cap T \times S : f(u, v) = 0$

otherwise  $c^f(v, u) > 0$  contradicting the definition of  $S$ .

$$\text{val}(f) = \sum_{e \in E \cap S \times T} f_e - \sum_{e \in E \cap T \times S} f_e \quad \text{Lemma 1}$$

$$= \sum_{e \in E \cap S \times T} f_e \quad \text{Observation above}$$

$$= \sum_{e \in E \cap S \times T} c_{(u,v)} = (S, T) \text{ cut capacity}$$

see next slide

# Max-Flow-Min-Cut theorem

**Theorem:** Max-flow = min-cut

**Proof:**

obvious: any-flow  $\leq$  max-flow  $\leq$  min-cut  $\leq$  any-cut

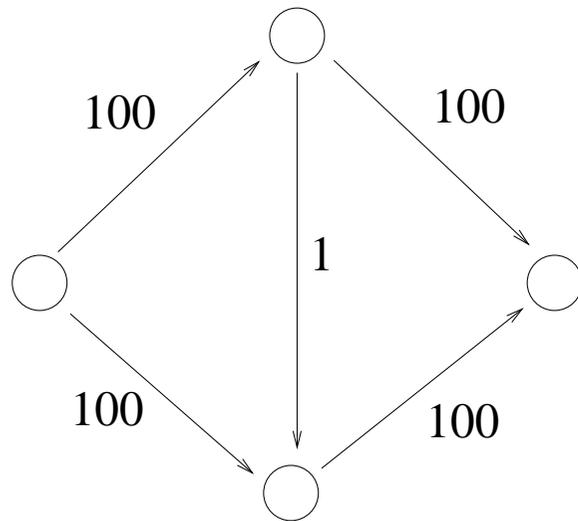
previous slide:

$(S, T)$  flow =  $(S, T)$  cut capacity

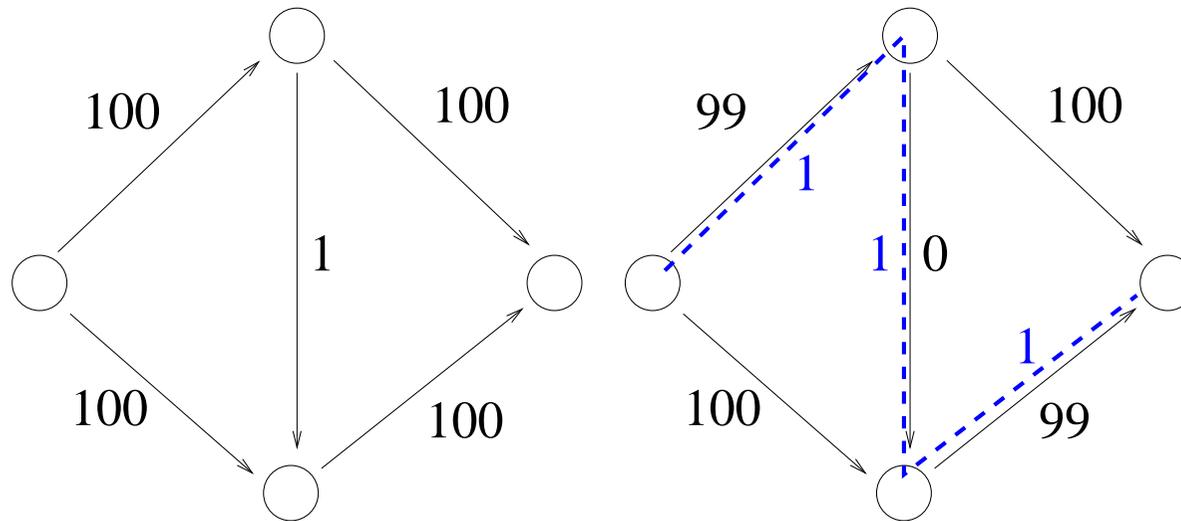
$\Rightarrow$

$(S, T)$  flow = max-flow = min-cut

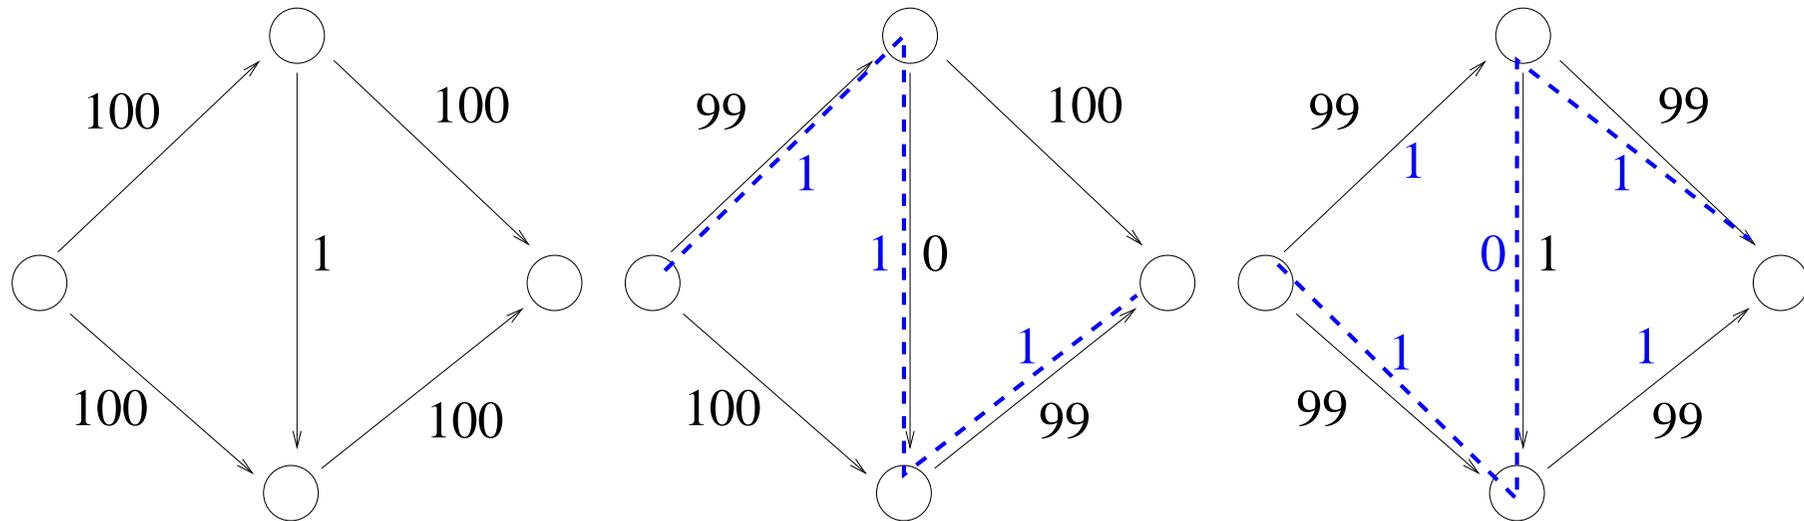
# A Bad Example for Ford Fulkerson



# A Bad Example for Ford Fulkerson



# A Bad Example for Ford Fulkerson

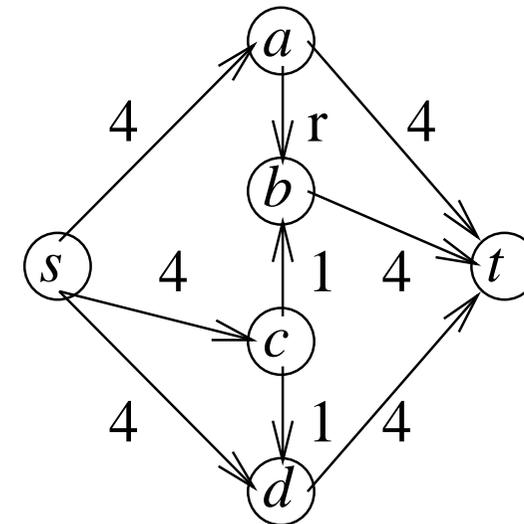


## An Even Worse Example for Ford Fulkerson

[U. Zwick, TCS 148, p. 165–170, 1995]

$$\text{Let } r = \frac{\sqrt{5} - 1}{2}.$$

Consider the graph



And the augmenting paths

$$p_0 = \langle s, c, b, t \rangle$$

$$p_1 = \langle s, a, b, c, d, t \rangle$$

$$p_2 = \langle s, c, b, a, t \rangle$$

$$p_3 = \langle s, d, c, b, t \rangle$$

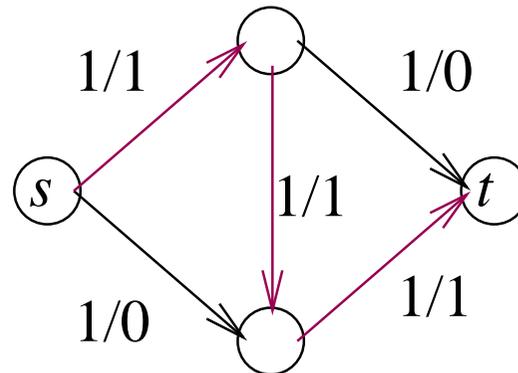
The sequence of augmenting paths  $p_0(p_1, p_2, p_1, p_3)^*$  is an infinite sequence of positive flow augmentations.

The flow value does **not** converge to the maximum value 9.

# Blocking Flows

$f_b$  is a **blocking flow** in  $H$  if

$$\forall \text{paths } p = \langle s, \dots, t \rangle : \exists e \in p : f_b(e) = c(e)$$



# Dinitz Algorithm

**Function** DinitzMaxFlow( $G = (V, E), s, t, c : E \rightarrow \mathbb{N}$ ) :  $E \rightarrow \mathbb{N}$

$f := 0$

**while**  $\exists$  path  $p = (s, \dots, t)$  in  $G_f$  **do**

$d = G_f.\text{reverseBFS}(t) : V \rightarrow \mathbb{N}$

$L_f = (V, \{(u, v) \in E_f : d(v) = d(u) - 1\})$  // layer graph

    find a **blocking flow**  $f_b$  in  $L_f$

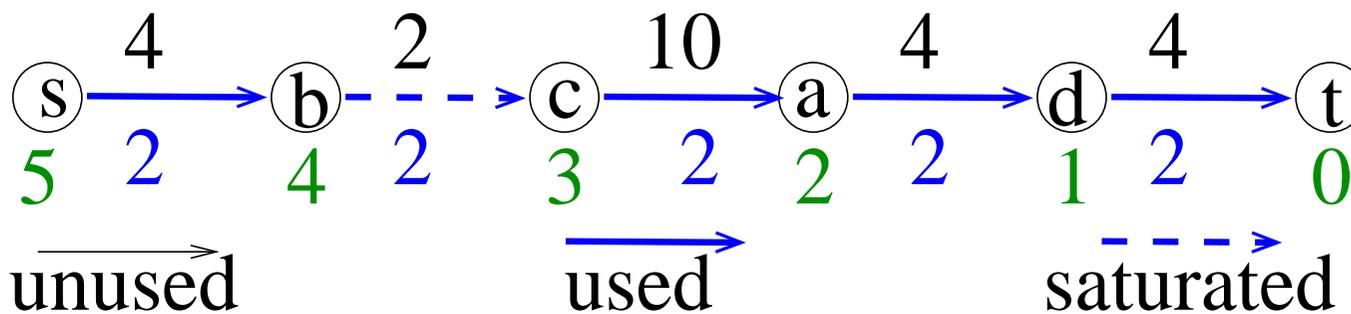
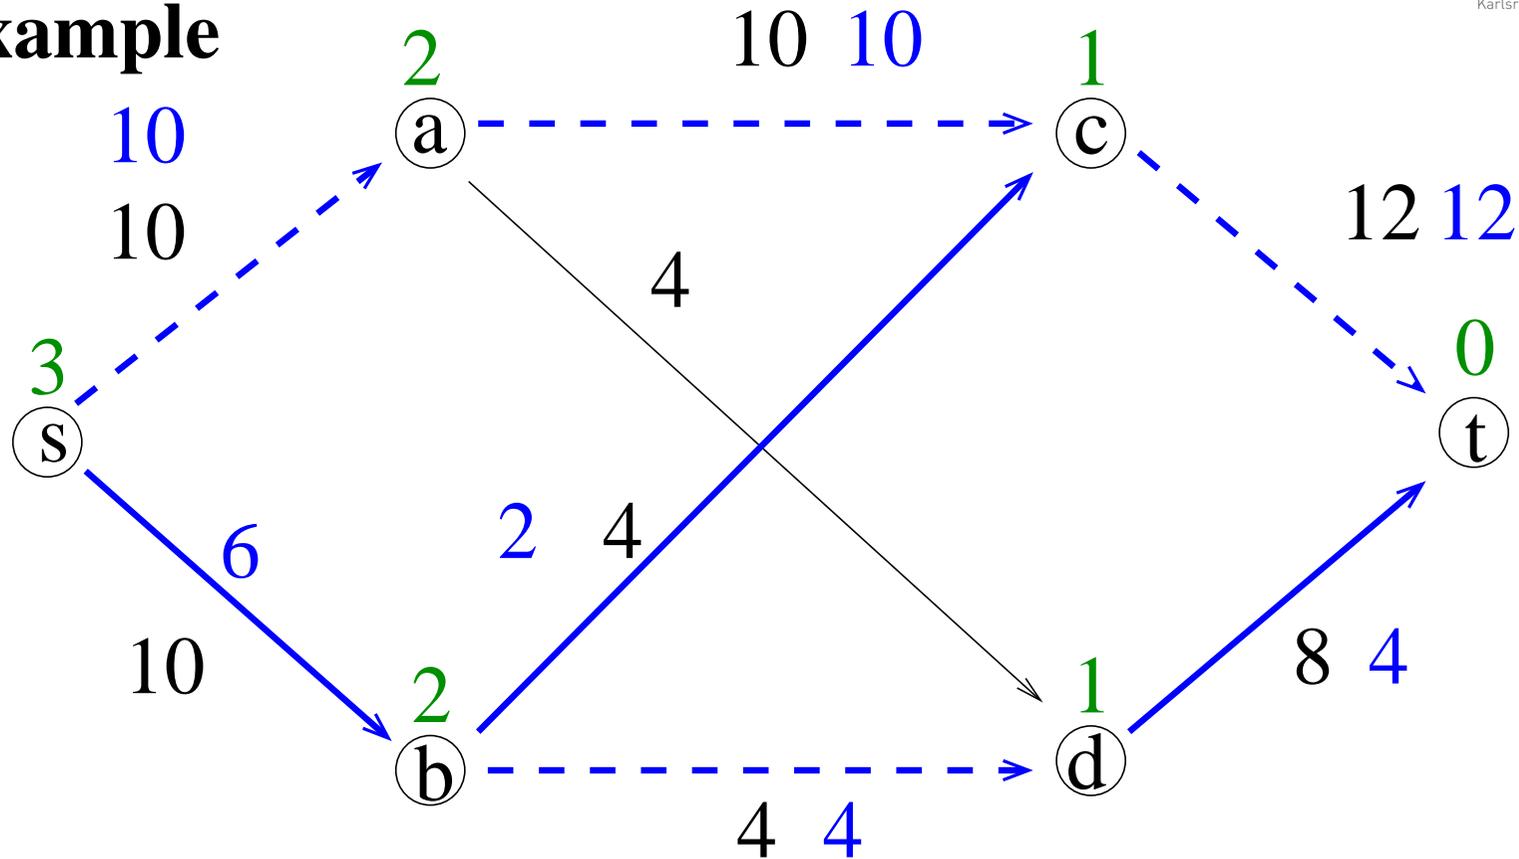
    augment  $f += f_b$

**return**  $f$

# **Dinitz – Correctness**

analogous to Ford-Fulkerson

# Example



# Computing Blocking Flows

Idee: wiederholte DFS nach augmentierenden Pfaden

**Function** blockingFlow( $L_f = (V, E)$ ) :  $E \rightarrow \mathbb{N}$

$p = \langle s \rangle$  : Path;      $f_b = 0$  : Flow

**loop**

// Round

$v := p.\text{last}()$

**if**  $v = t$  **then**

// breakthrough

$\delta := \min \{c(e) - f_b(e) : e \in p\}$

**foreach**  $e \in p$  **do**

$f_b(e) += \delta$

**if**  $f_b(e) = c(e)$  **then** remove  $e$  from  $E$

$p := \langle s \rangle$

**else if**  $\exists e = (v, w) \in E$  **then**  $p.\text{pushBack}(w)$

// extend

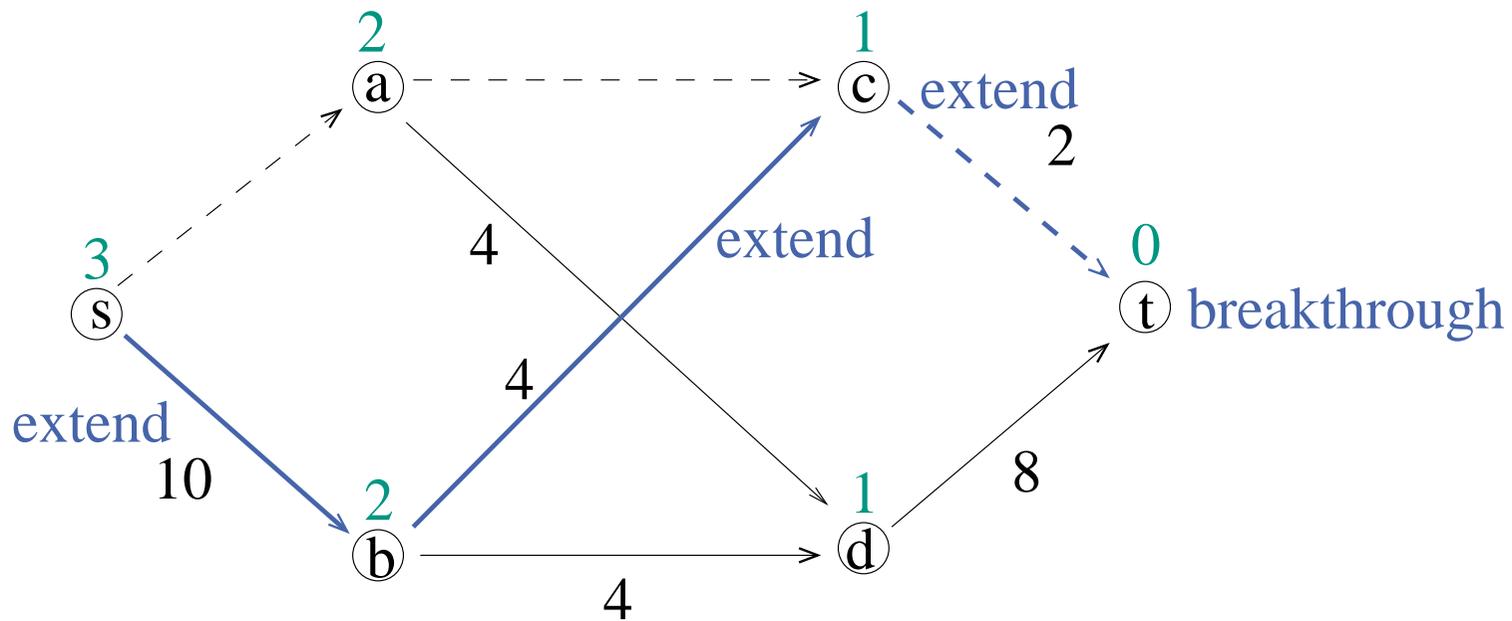
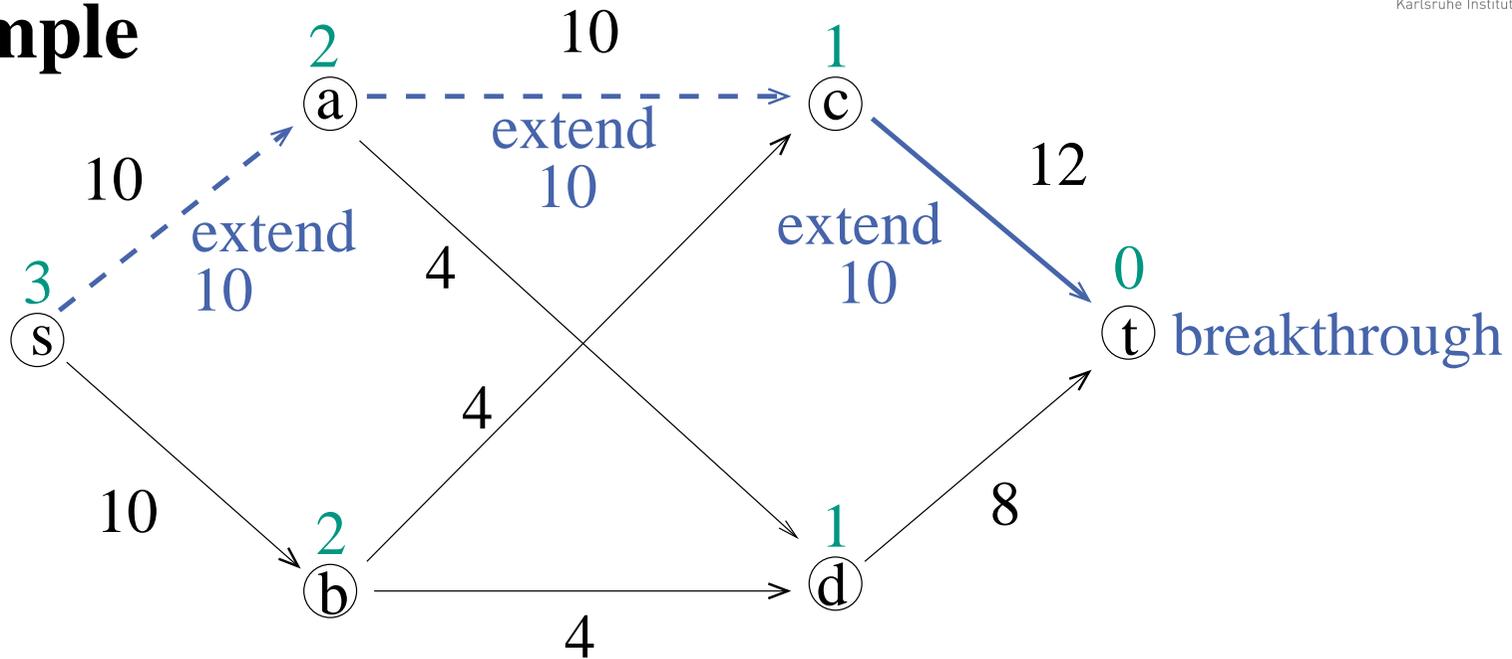
**else if**  $v = s$  **then return**  $f_b$

// done

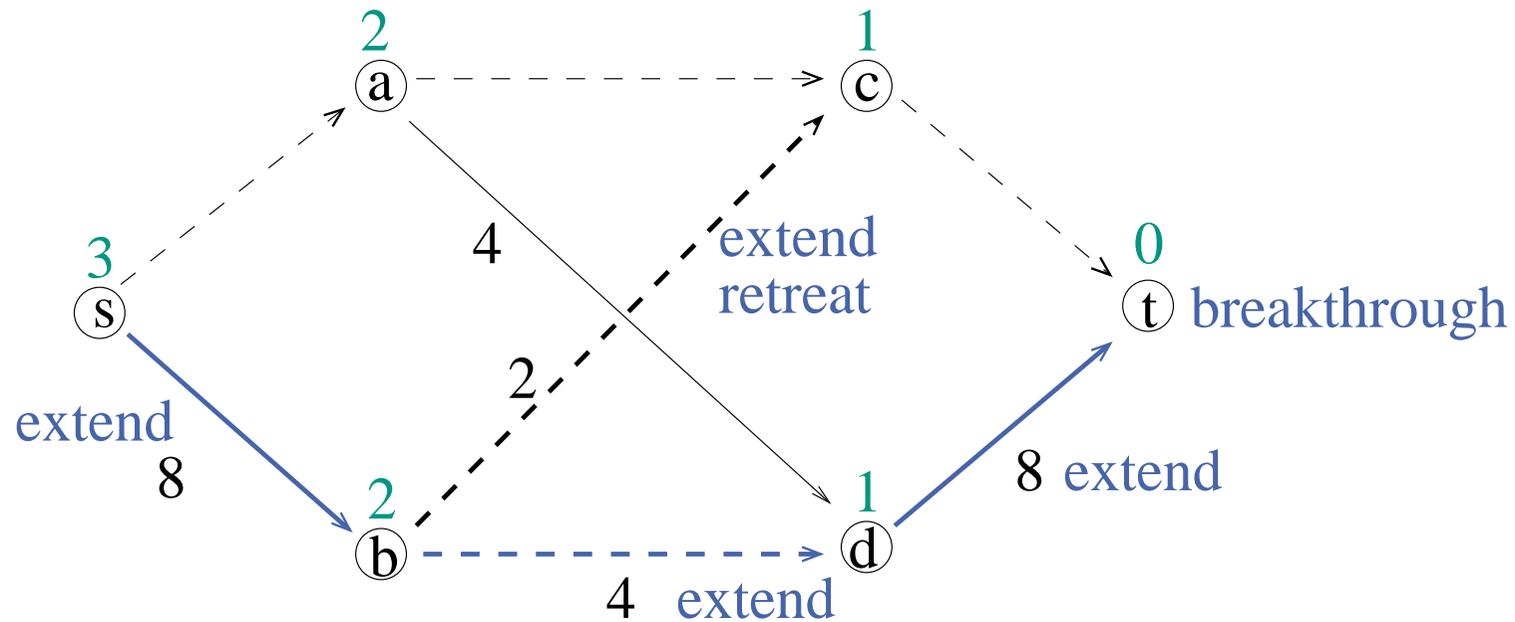
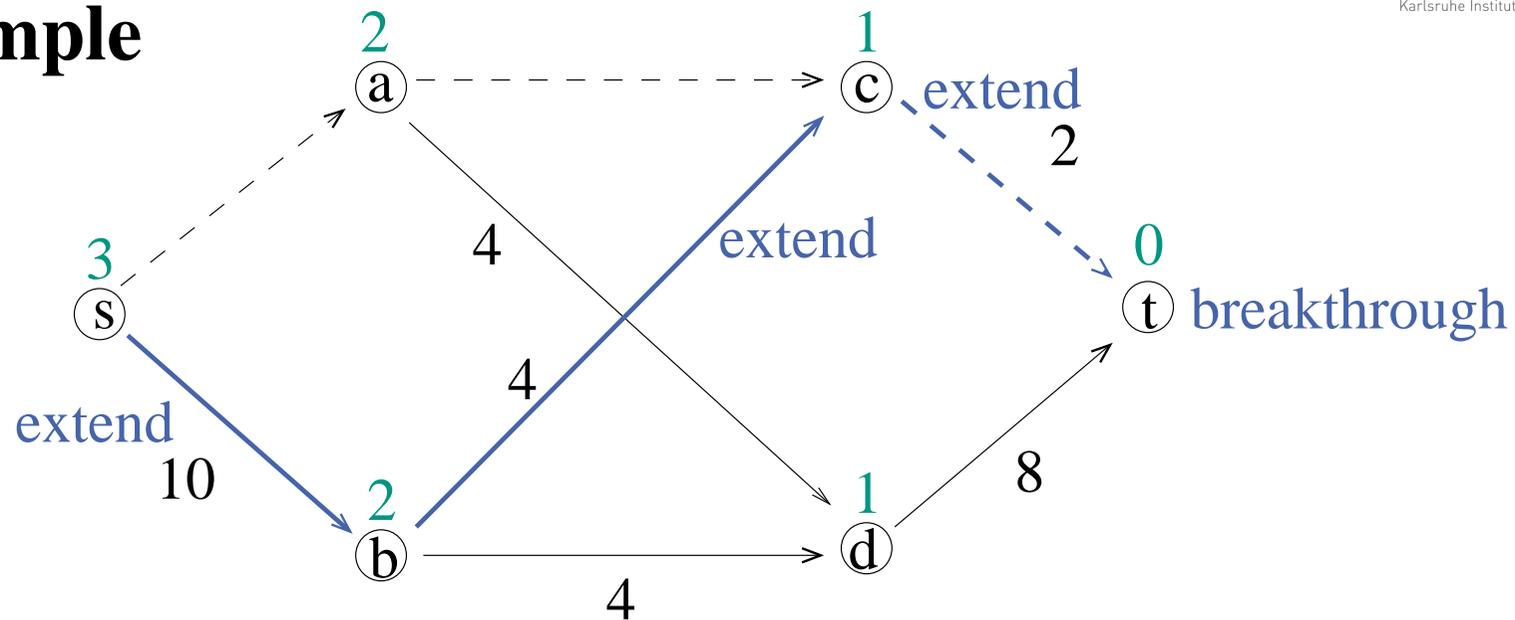
**else** delete the last edge from  $p$  in  $p$  and  $E$

// retreat

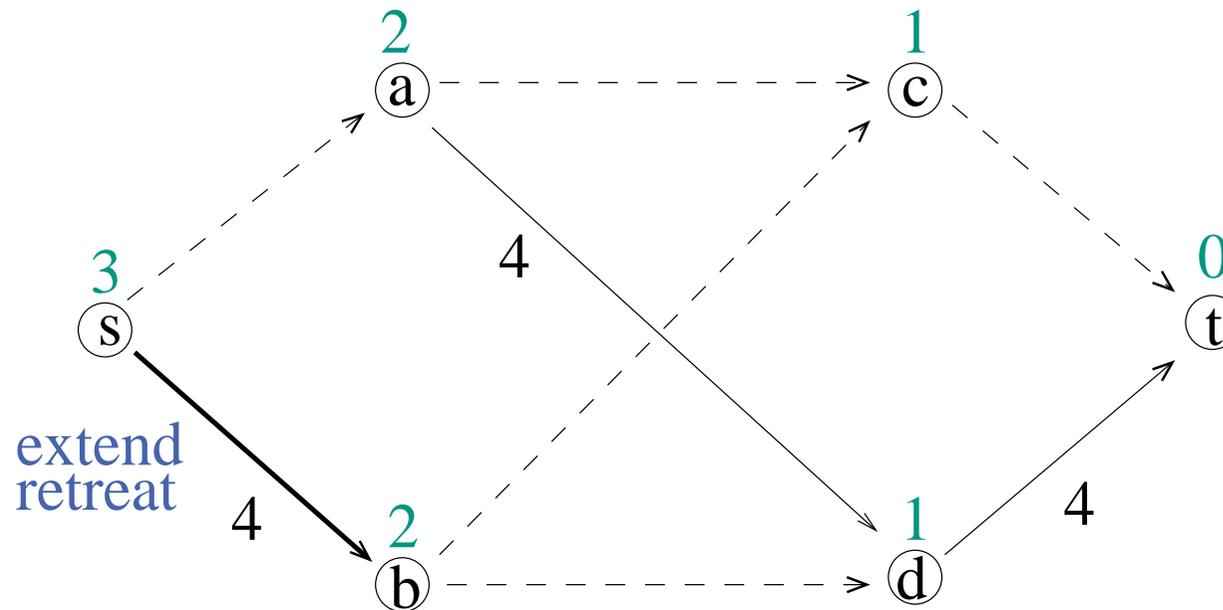
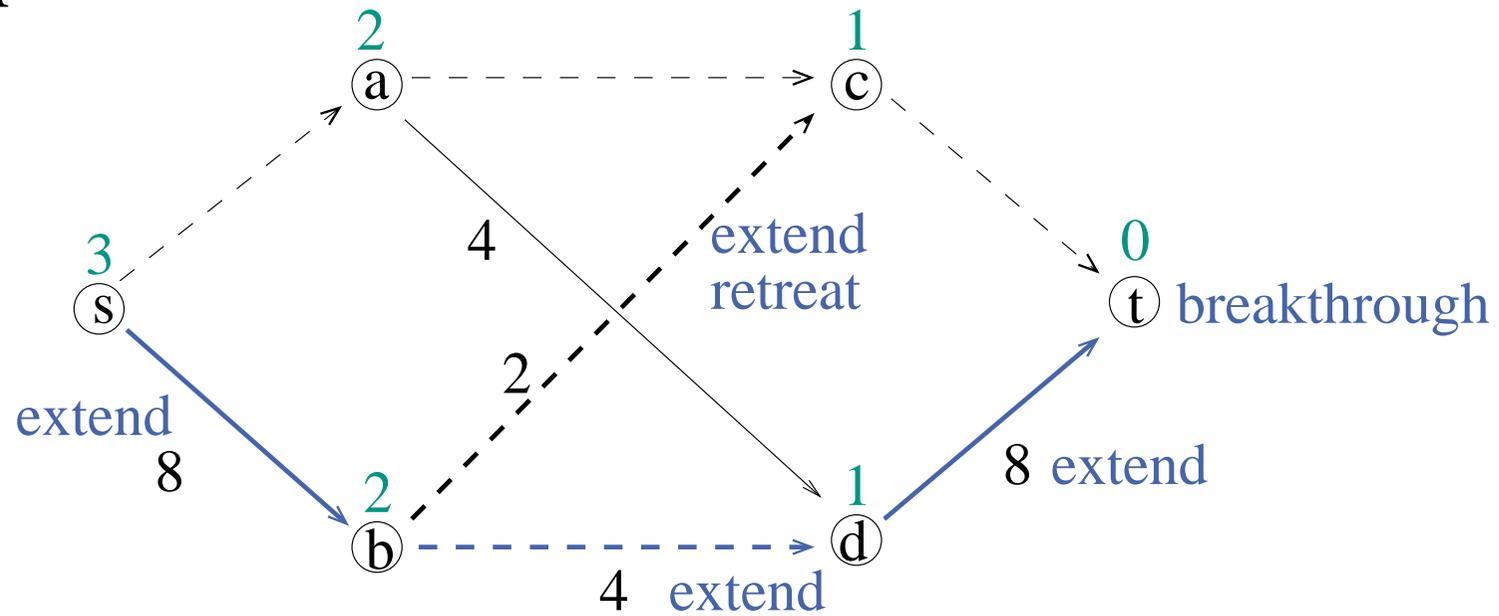
# Example



# Example



# Example



# Blocking Flows Analysis 1

- running time  $\#_{extends} + \#_{retreats} + n \cdot \#_{breakthroughs}$
- $\#_{breakthroughs} \leq m$  –  $\geq 1$  edge is saturated
- $\#_{retreats} \leq m$  – one edge is removed
- $\#_{extends} \leq \#_{retreats} + n \cdot \#_{breakthroughs}$ 
  - a retreat cancels 1 extend, a breakthrough cancels  $\leq n$  extends

time is  $O(m + nm) = O(nm)$

## Blocking Flows Analysis 2

### Unit capacities:

breakthroughs saturates **all** edges on  $p$ , i.e., amortized constant cost per edge.

time  $O(m + n)$

## Blocking Flows Analysis 3

Dynamic trees: breakthrough (!), retreat, extend in time  $O(\log n)$

time  $O((m + n) \log n)$

“Theory alert”: In practice, this seems to be slower  
(few breakthroughs, many retreat, extend ops.)

# Dinitz Analysis 1

**Lemma 1.**  *$d(s)$  increases by at least one in each round.*

*Beweis.* not here



## Dinitz Analysis 2

□  $\leq n$  rounds

□ time  $O(mn)$  each

time  $O(mn^2)$  (strongly polynomial)

time  $O(mn \log n)$  with dynamic trees

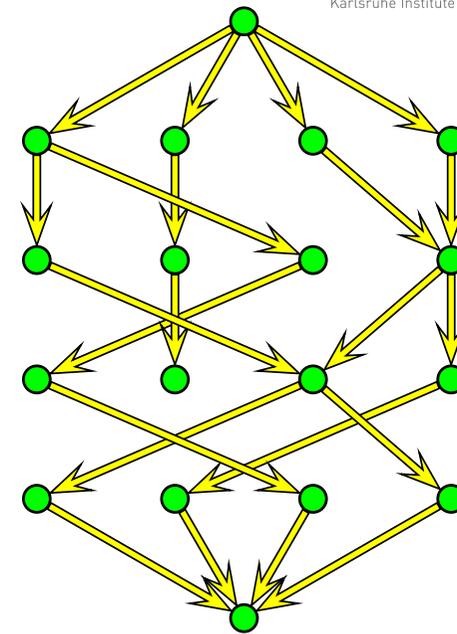
## Dinitz Analysis 3 – Unit Capacities

**Lemma 2.** *At most  $2\sqrt{m}$  BF computations:*

*Beweis.* Consider iteration  $k = \sqrt{m}$ .

Cut in layergraph induces cut in residual graph of capacity at most  $\sqrt{m}$ .

At most  $\sqrt{m}$  additional phases.



Total time:  $O((m+n)\sqrt{m})$

more detailed analysis:  $O\left(m \min \left\{ m^{1/2}, n^{2/3} \right\}\right)$

## Dinitz Analysis 4 – Unit Networks

Unit capacity +  $\forall v \in V : \min \{ \text{indegree}(v), \text{outdegree}(v) \} = 1$ :

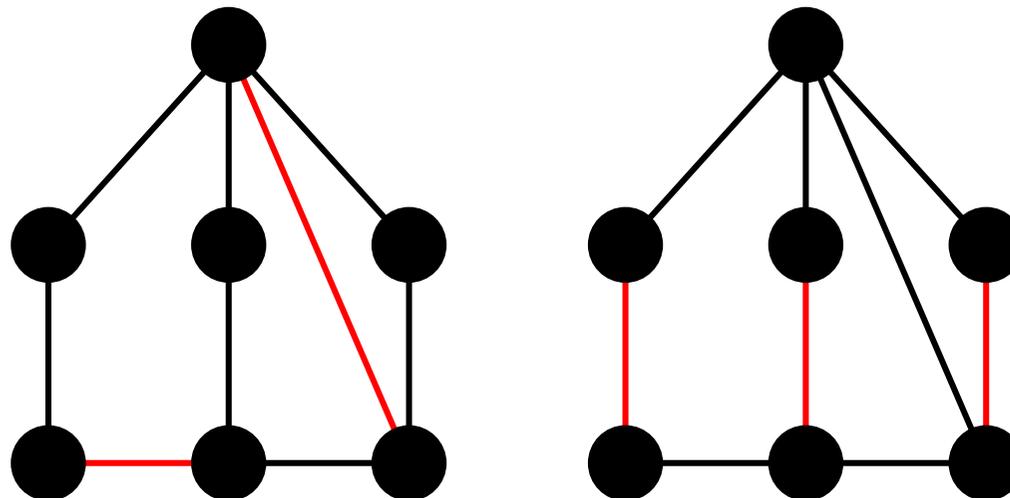
time:  $O((m+n)\sqrt{n})$

# Matching

$M \subseteq E$  is a **matching** in the undirected graph  $G = (V, E)$  iff  $(V, M)$  has maximum degree  $\leq 1$ .

$M$  is **maximal** if  $\nexists e \in E \setminus M : M \cup \{e\}$  is a matching.

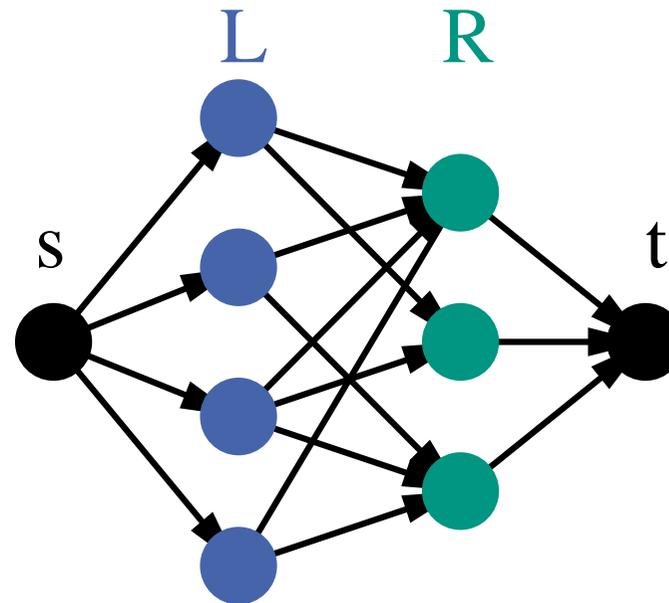
$M$  has **maximum** cardinality if  $\nexists$  matching  $M' : |M'| > |M|$



# Maximum Cardinality Bipartite Matching

in  $(L \cup R, E)$ . Model as a **unit network maximum flow** problem

$$(\{s\} \cup L \cup R \cup \{t\}, \{(s, u) : u \in L\} \cup E \cup \{(v, t) : v \in R\})$$

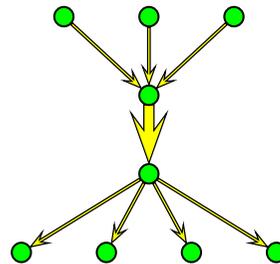


Dinitz algorithm yields  $O((n + m)\sqrt{n})$  algorithm

## Similar Performance for Weighted Graphs?

time:  $O\left(m \min\left\{m^{1/2}, n^{2/3}\right\} \log C\right)$  [Goldberg Rao 97]

**Problem:** Fat edges between layers ruin the argument

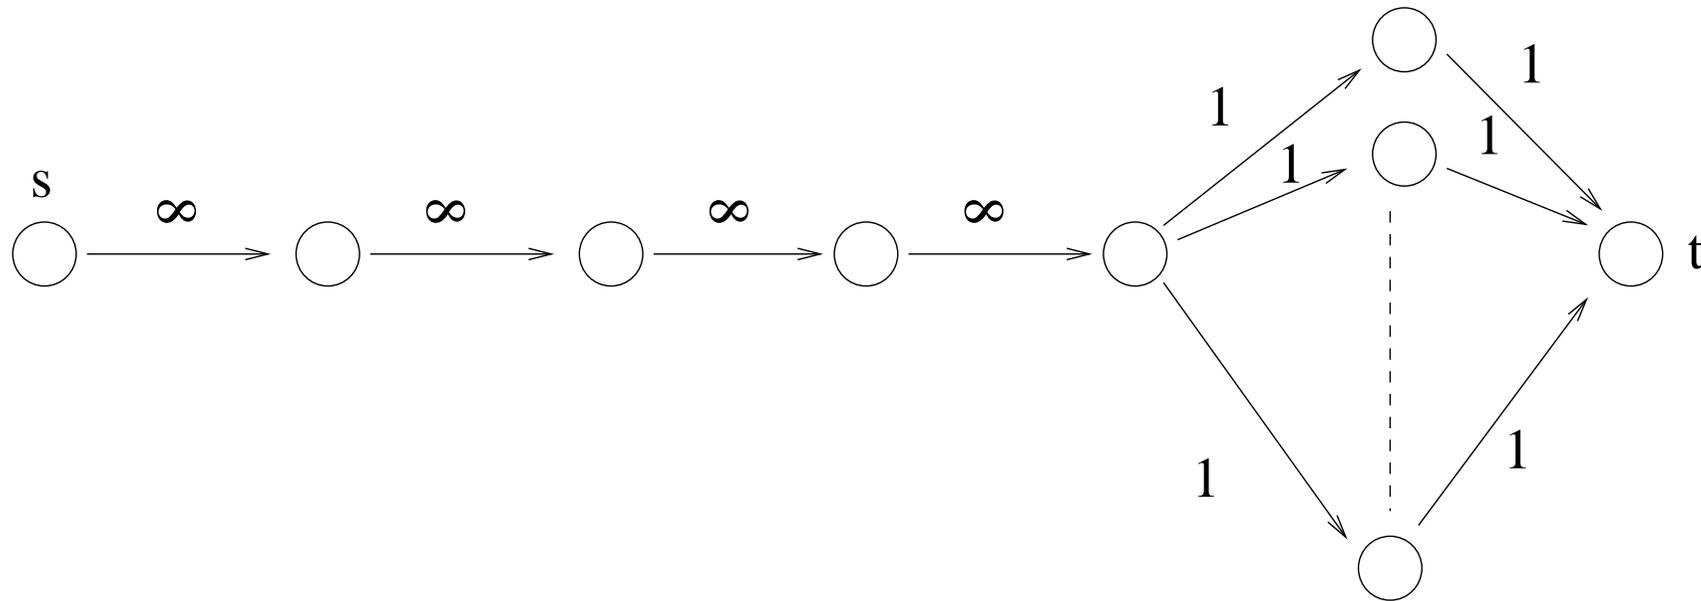


Idea: **scale** a parameter  $\Delta$  from small to large  
contract SCCs of fat edges (capacity  $> \Delta$ )

Experiments [Hagerup, Sanders Träff 98]:

Sometimes best algorithm usually slower than **preflow push**

# Disadvantage of augmenting paths algorithms



# Preflow-Push Algorithms

**Preflow**  $f$ : a flow where the **flow conservation** constraint is **relaxed** to

$$\text{excess}(v) := \overbrace{\sum_{(u,v) \in E} f_{(u,v)}}^{\text{inflow}} - \overbrace{\sum_{(v,w) \in E} f_{(v,w)}}^{\text{outflow}} \geq 0 .$$

$v \in V \setminus \{s, t\}$  is **active** iff  $\text{excess}(v) > 0$

**Procedure**  $\text{push}(e = (v, w), \delta)$

**assert**  $\delta > 0 \quad \wedge \quad \text{excess}(v) \geq \delta$

**assert** residual capacity of  $e \geq \delta$

$\text{excess}(v) - = \delta$

$\text{excess}(w) + = \delta$

**if**  $e$  is reverse edge **then**  $f(\text{reverse}(e)) - = \delta$

**else**  $f(e) + = \delta$

# Level Function

Idea: make progress by pushing **towards**  $t$

Maintain

an **approximation**  $d(v)$  of the BFS distance from  $v$  to  $t$  in  $G_f$ .

**invariant**  $d(t) = 0$

**invariant**  $d(s) = n$

**invariant**  $\forall (v, w) \in E_f : d(v) \leq d(w) + 1$  // no **steep** edges

Edge directions of  $e = (v, w)$

**steep:**  $d(w) < d(v) - 1$

**downward:**  $d(w) < d(v)$

**horizontal:**  $d(w) = d(v)$

**upward:**  $d(w) > d(v)$

```

Procedure genericPreflowPush( $G=(V,E)$ ,  $f$ )
  forall  $e = (s, v) \in E$  do push( $e, c(e)$ ) // saturate
   $d(s) := n$ 
   $d(v) := 0$  for all other nodes
  while  $\exists v \in V \setminus \{s, t\} : \text{excess}(v) > 0$  do // active node
    if  $\exists e = (v, w) \in E_f : d(w) < d(v)$  then // eligible edge
      choose some  $\delta \leq \min \{ \text{excess}(v), c_e^f \}$ 
      push( $e, \delta$ ) // no new steep edges
    else  $d(v)++$  // relabel. No new steep edges
  
```

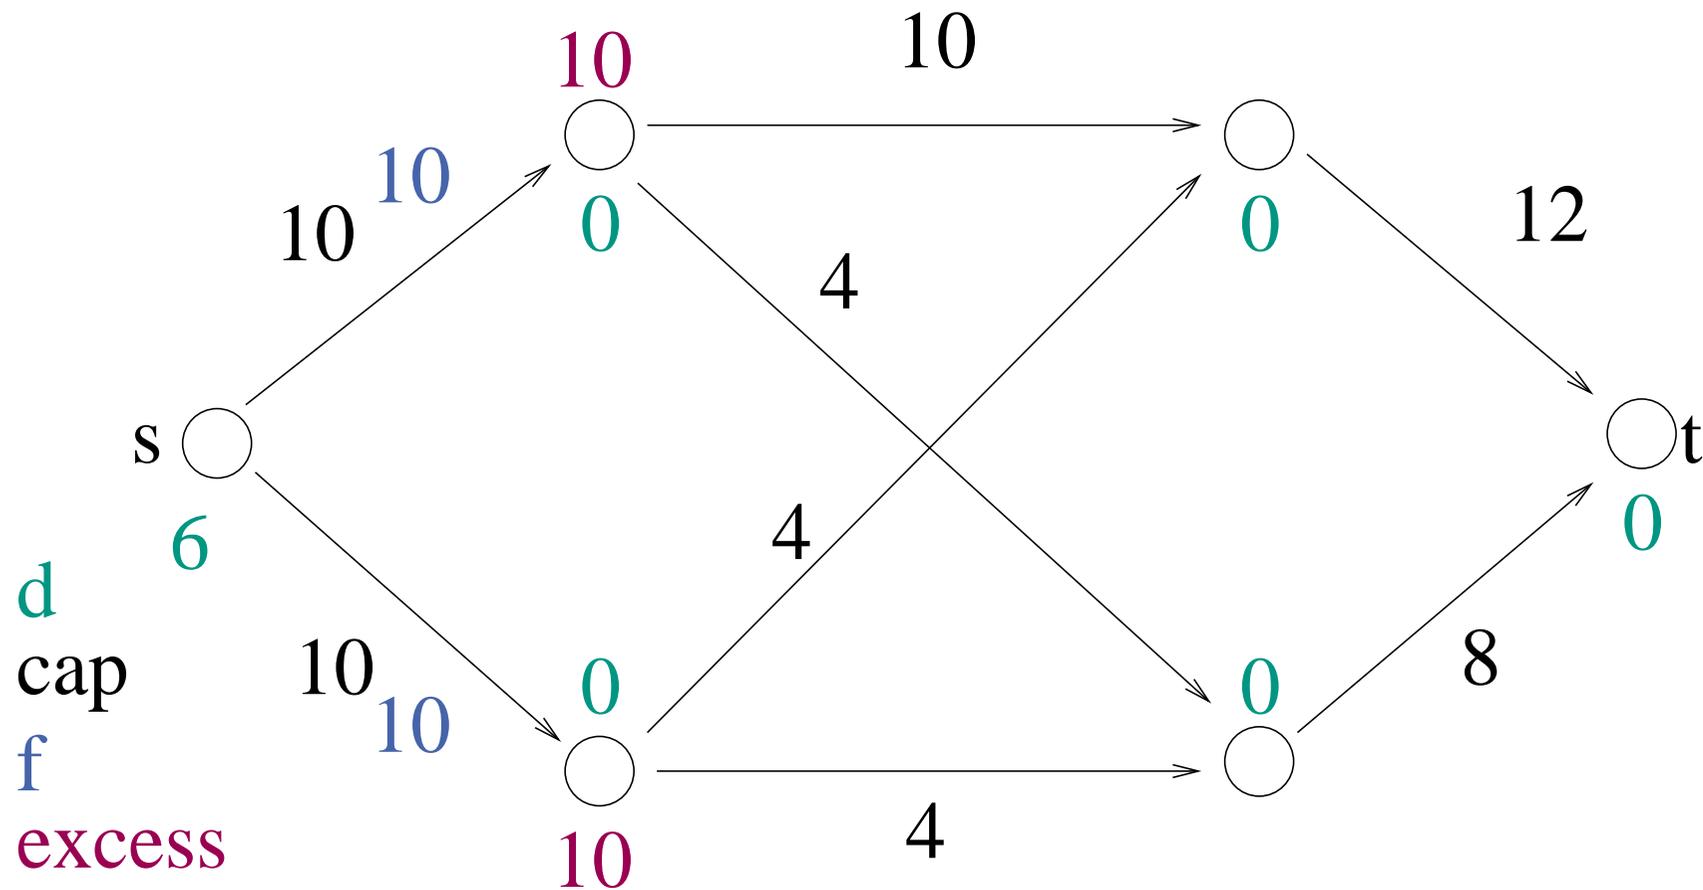
Obvious choice for  $\delta$  :  $\delta = \min \{ \text{excess}(v), c_e^f \}$

Saturating push:  $\delta = c_e^f$

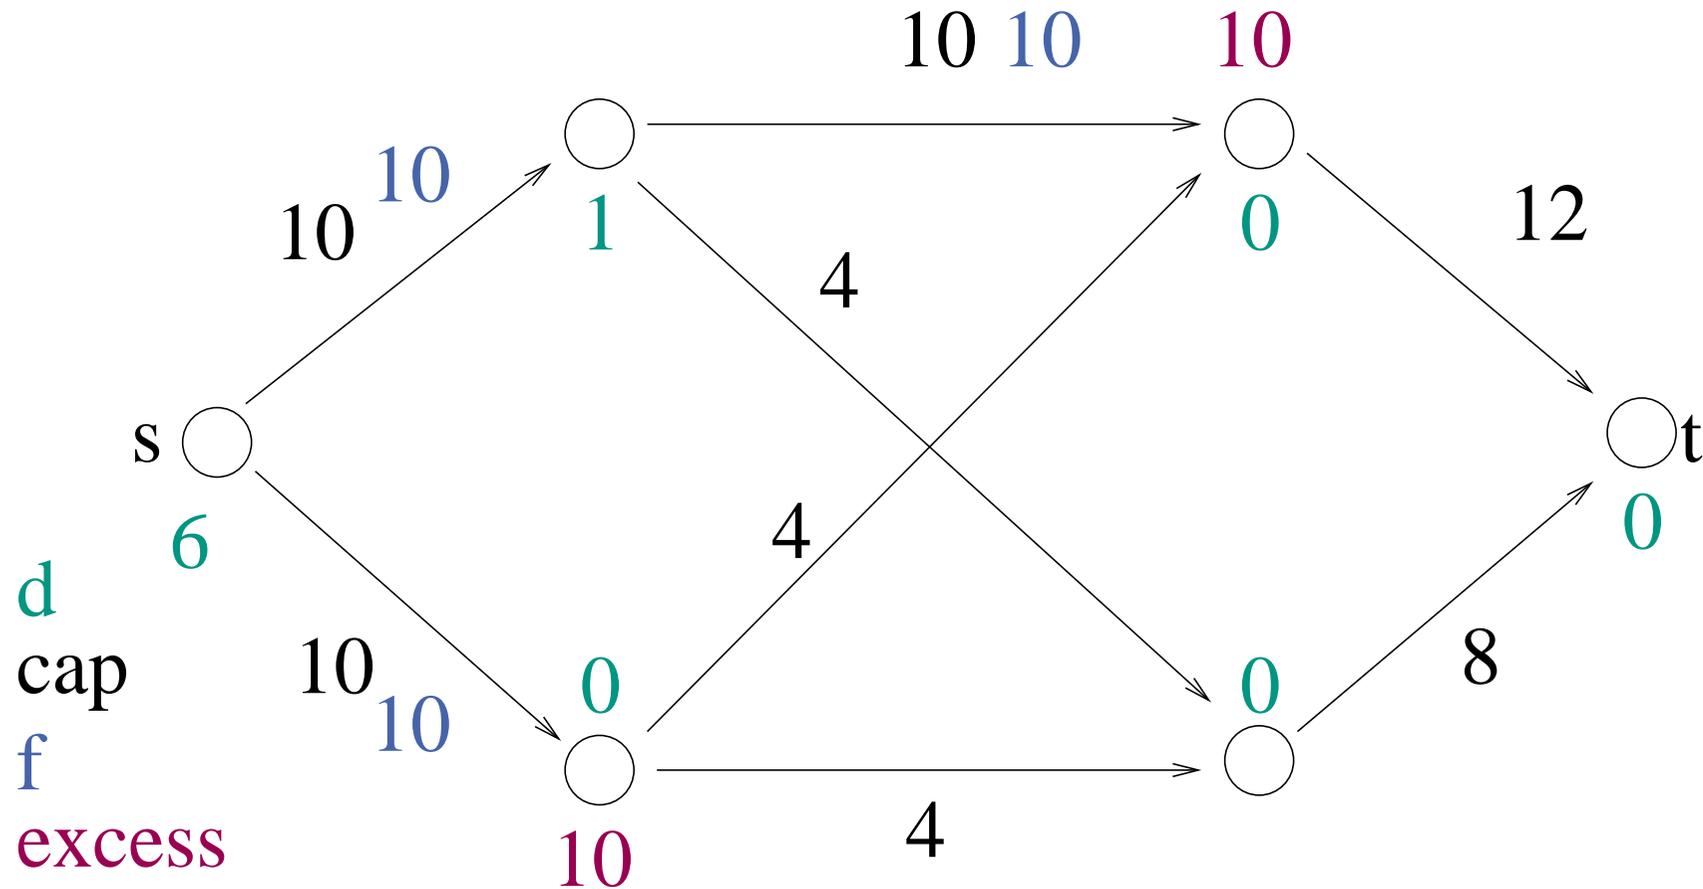
nonsaturating push:  $\delta < c_e^f$

To be filled in: How to select active nodes and eligible edges?

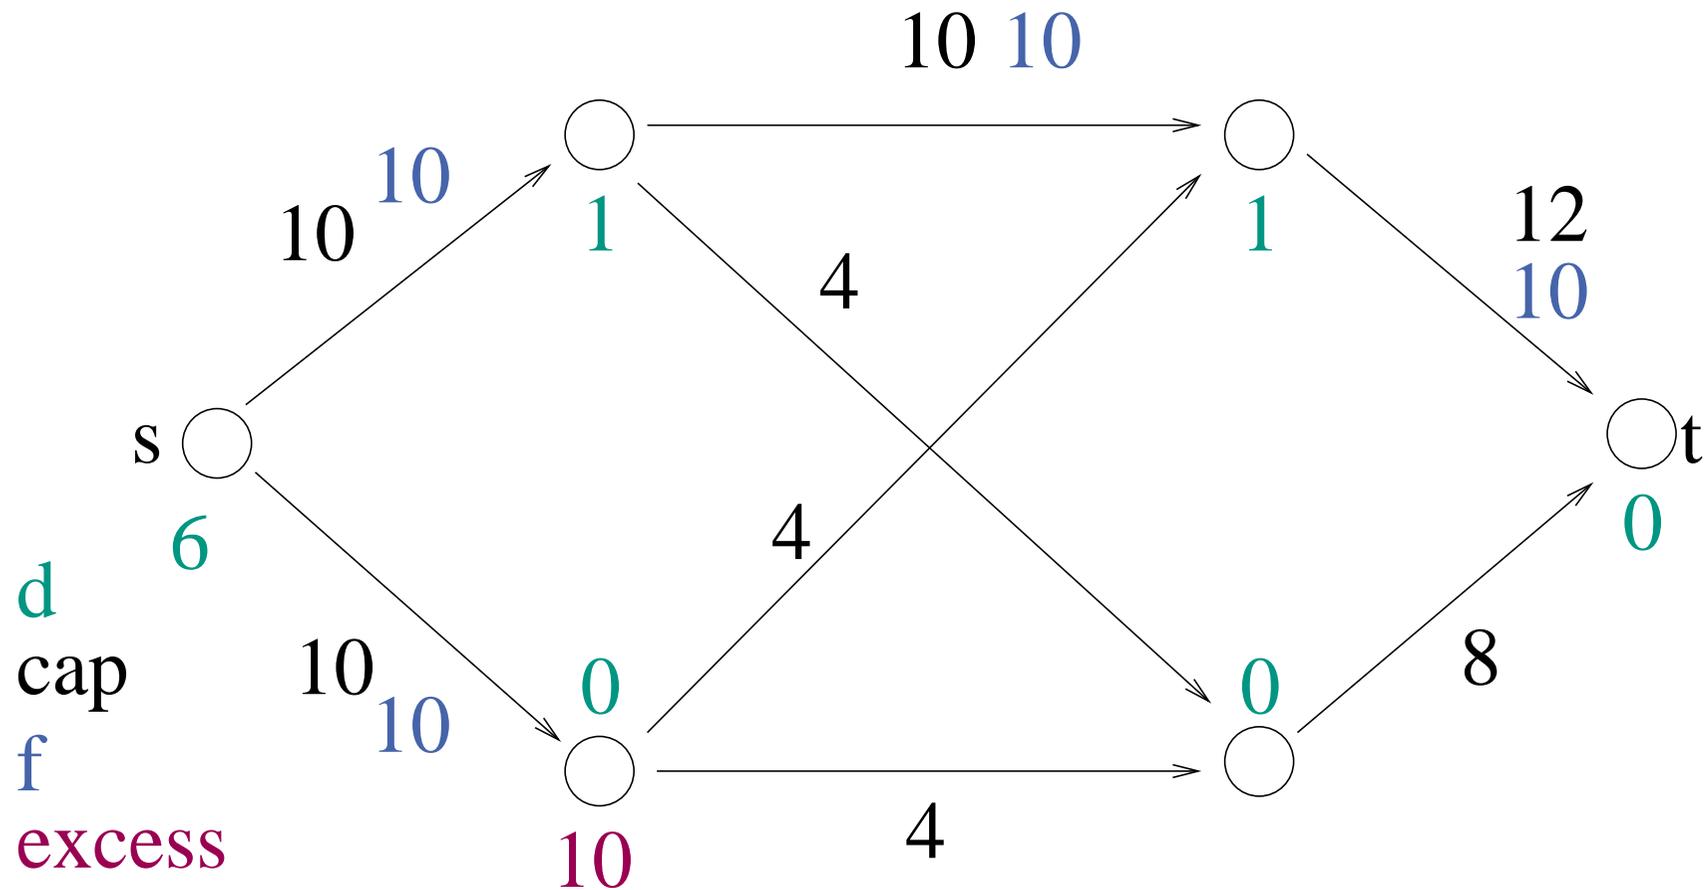
# Example



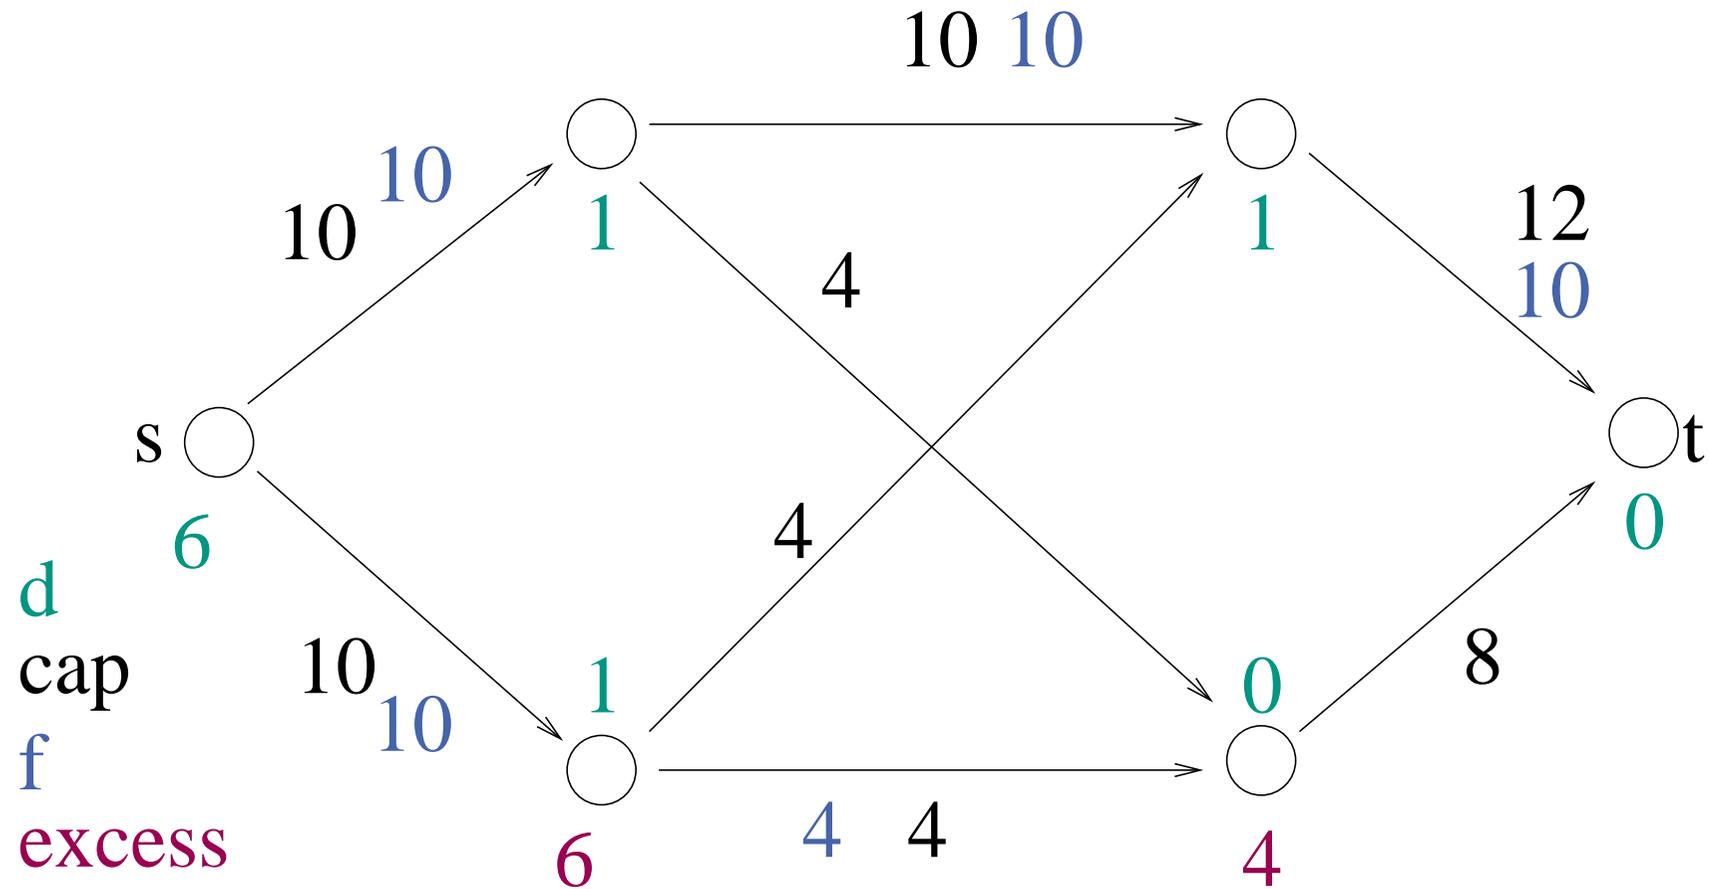
# Example



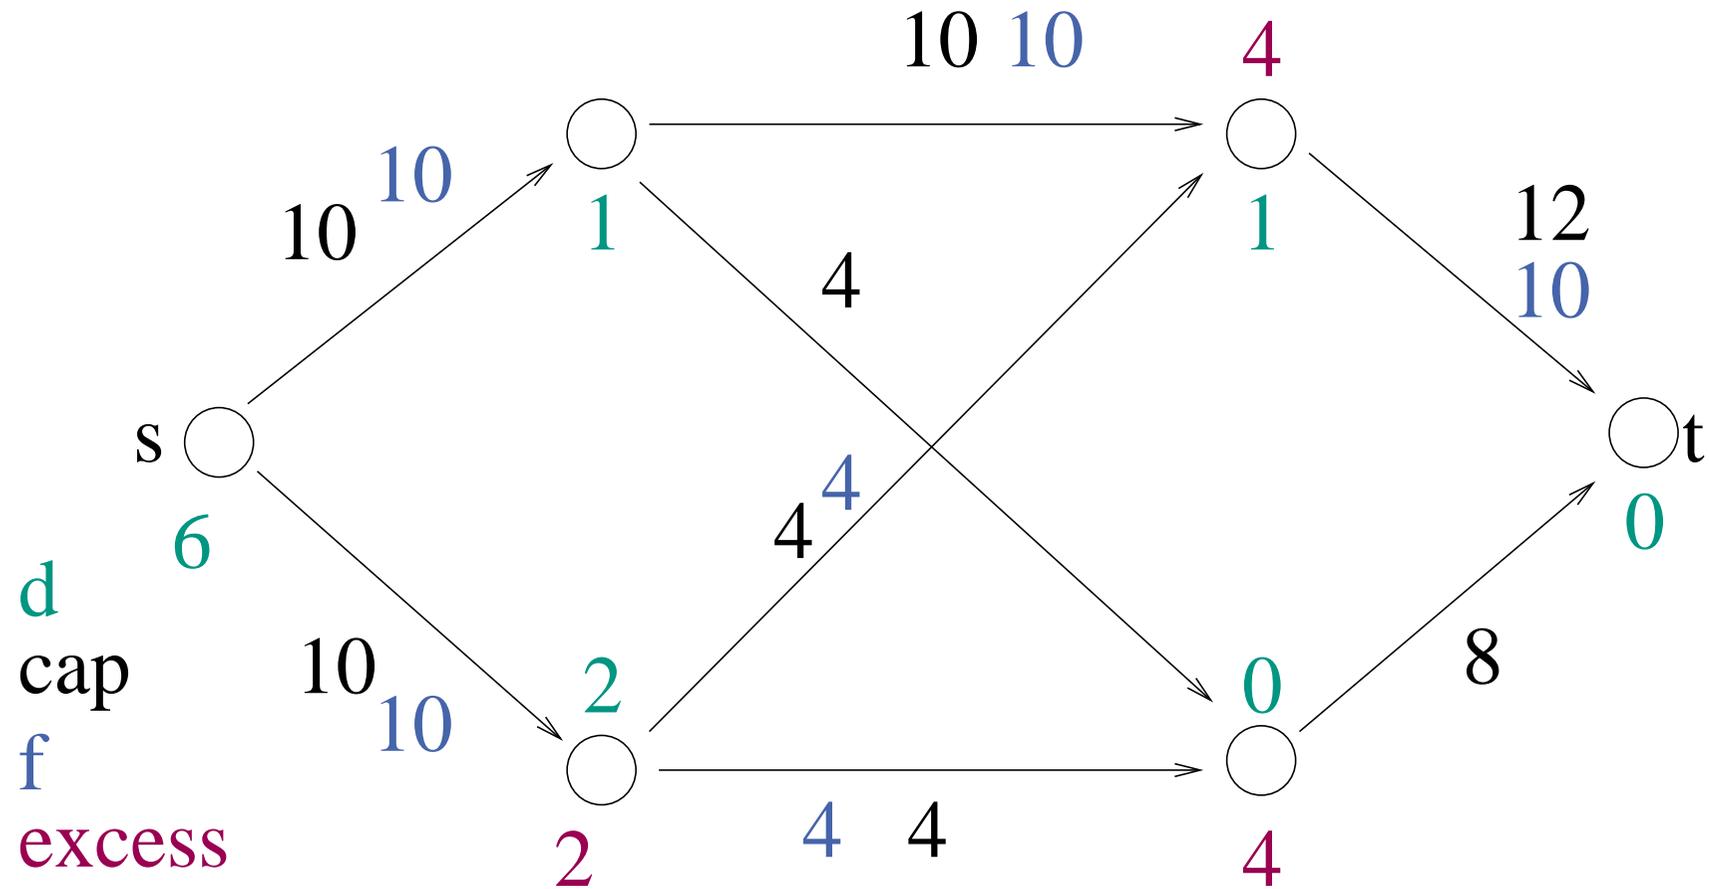
# Example



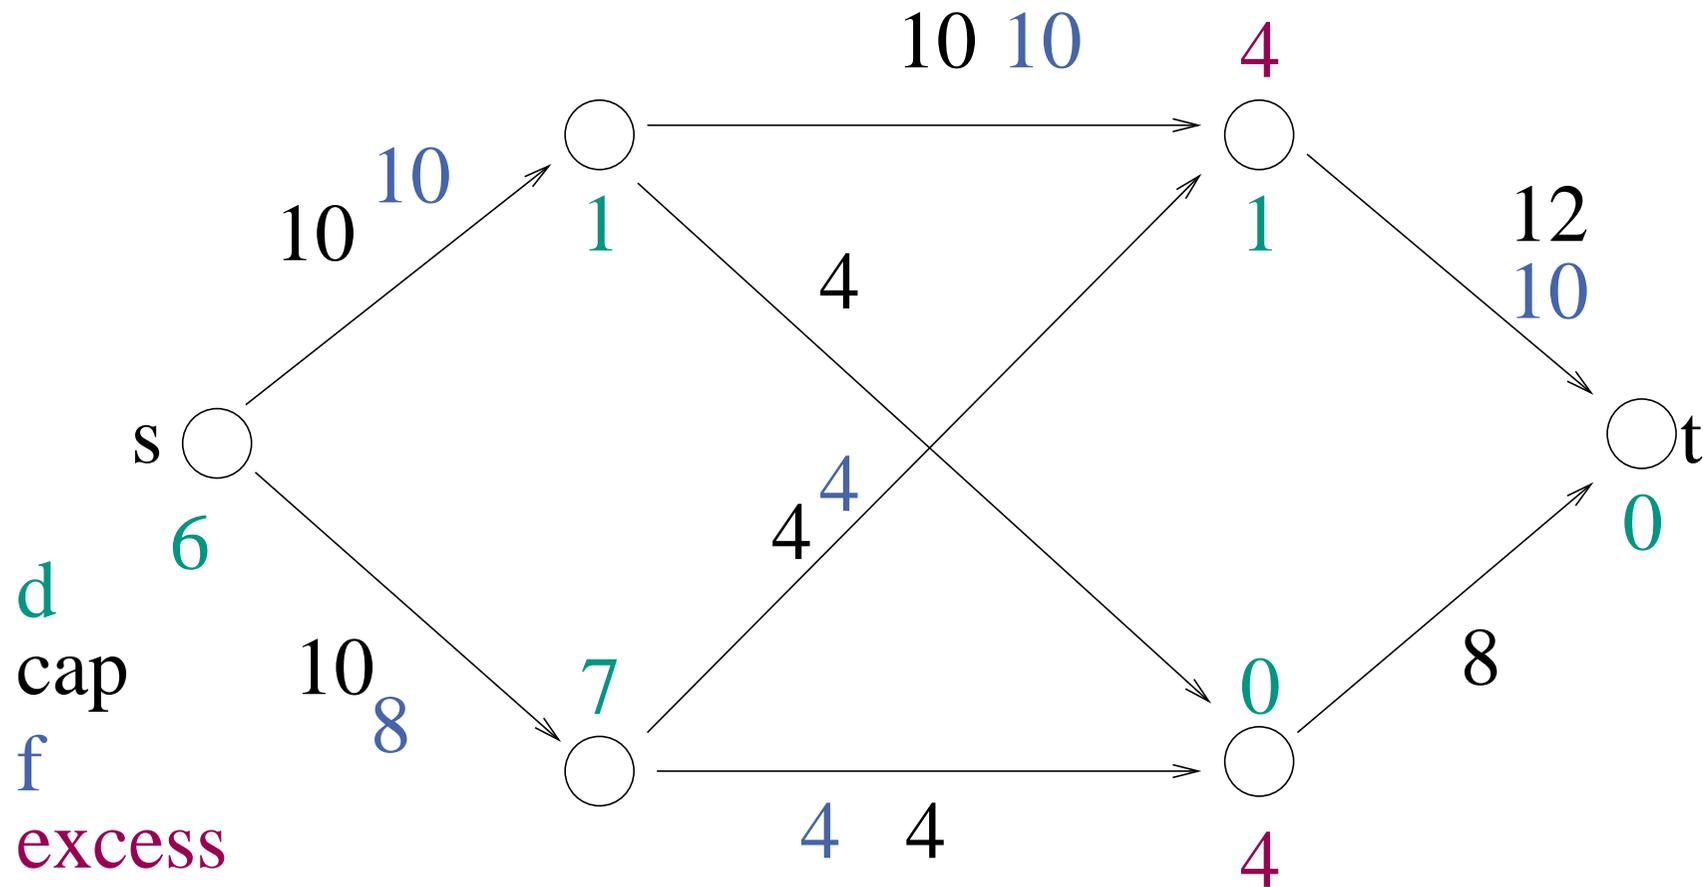
# Example



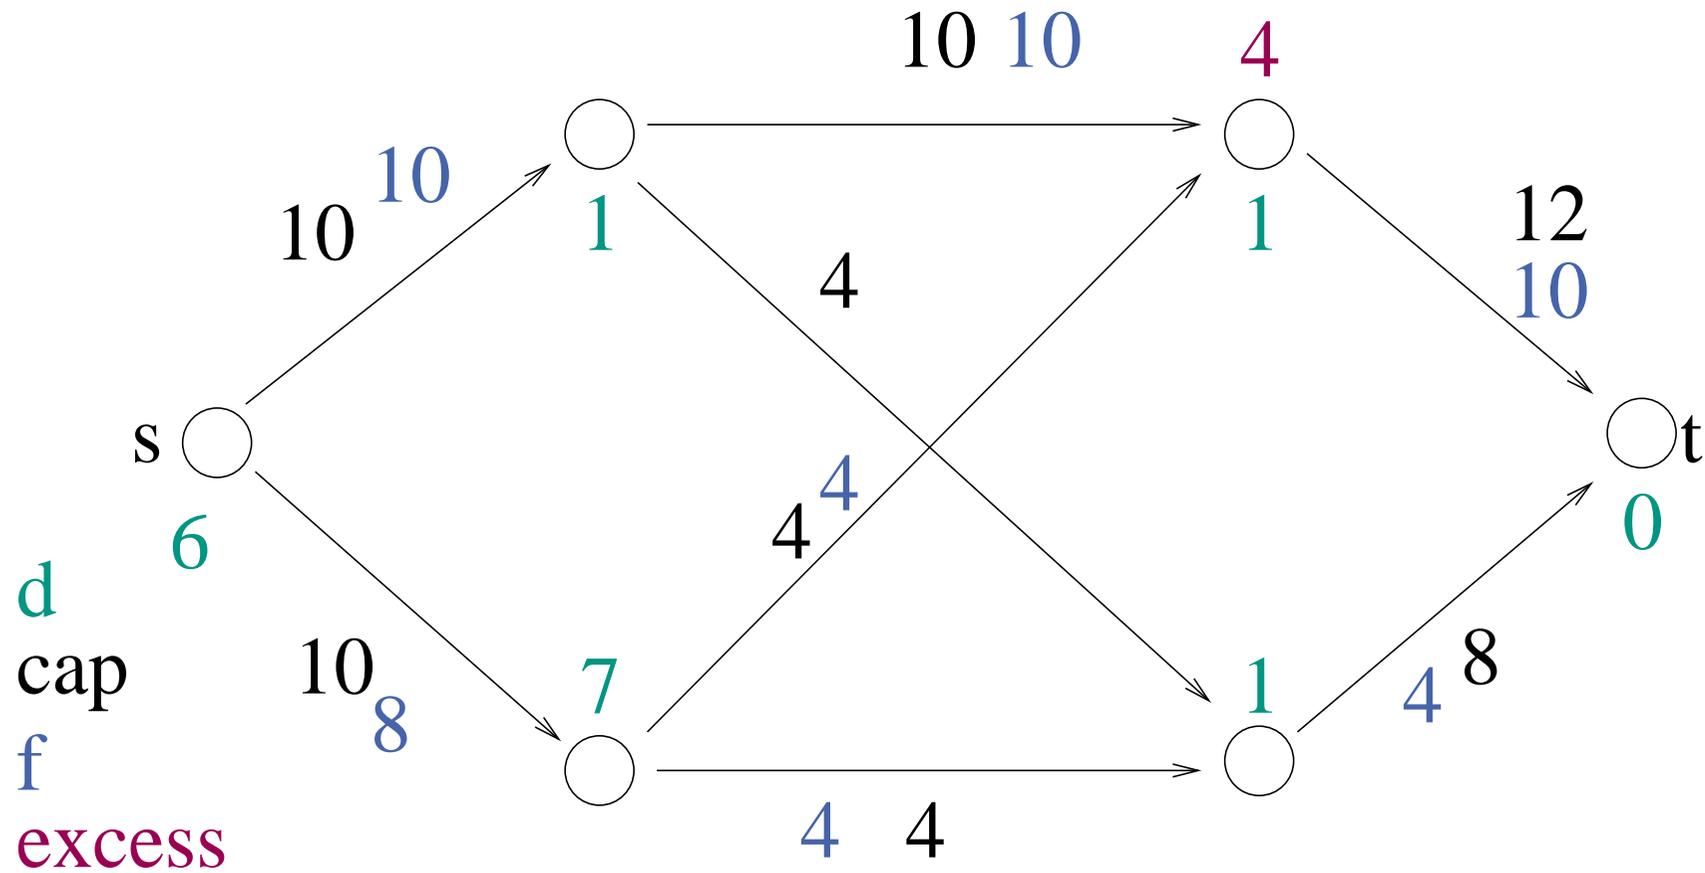
# Example



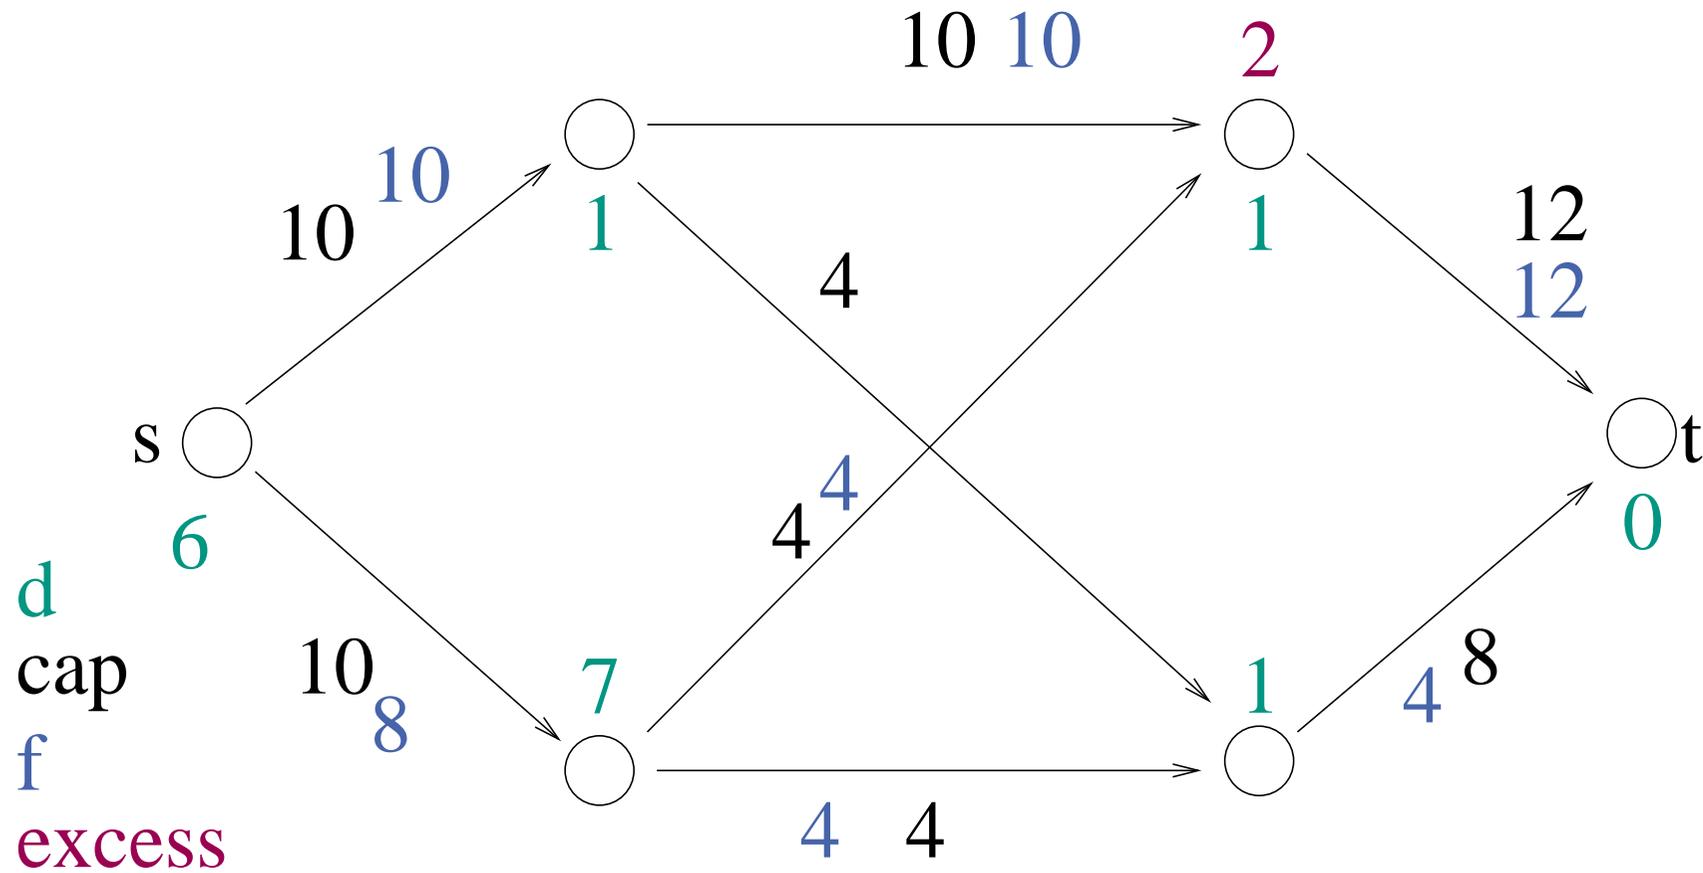
# Example



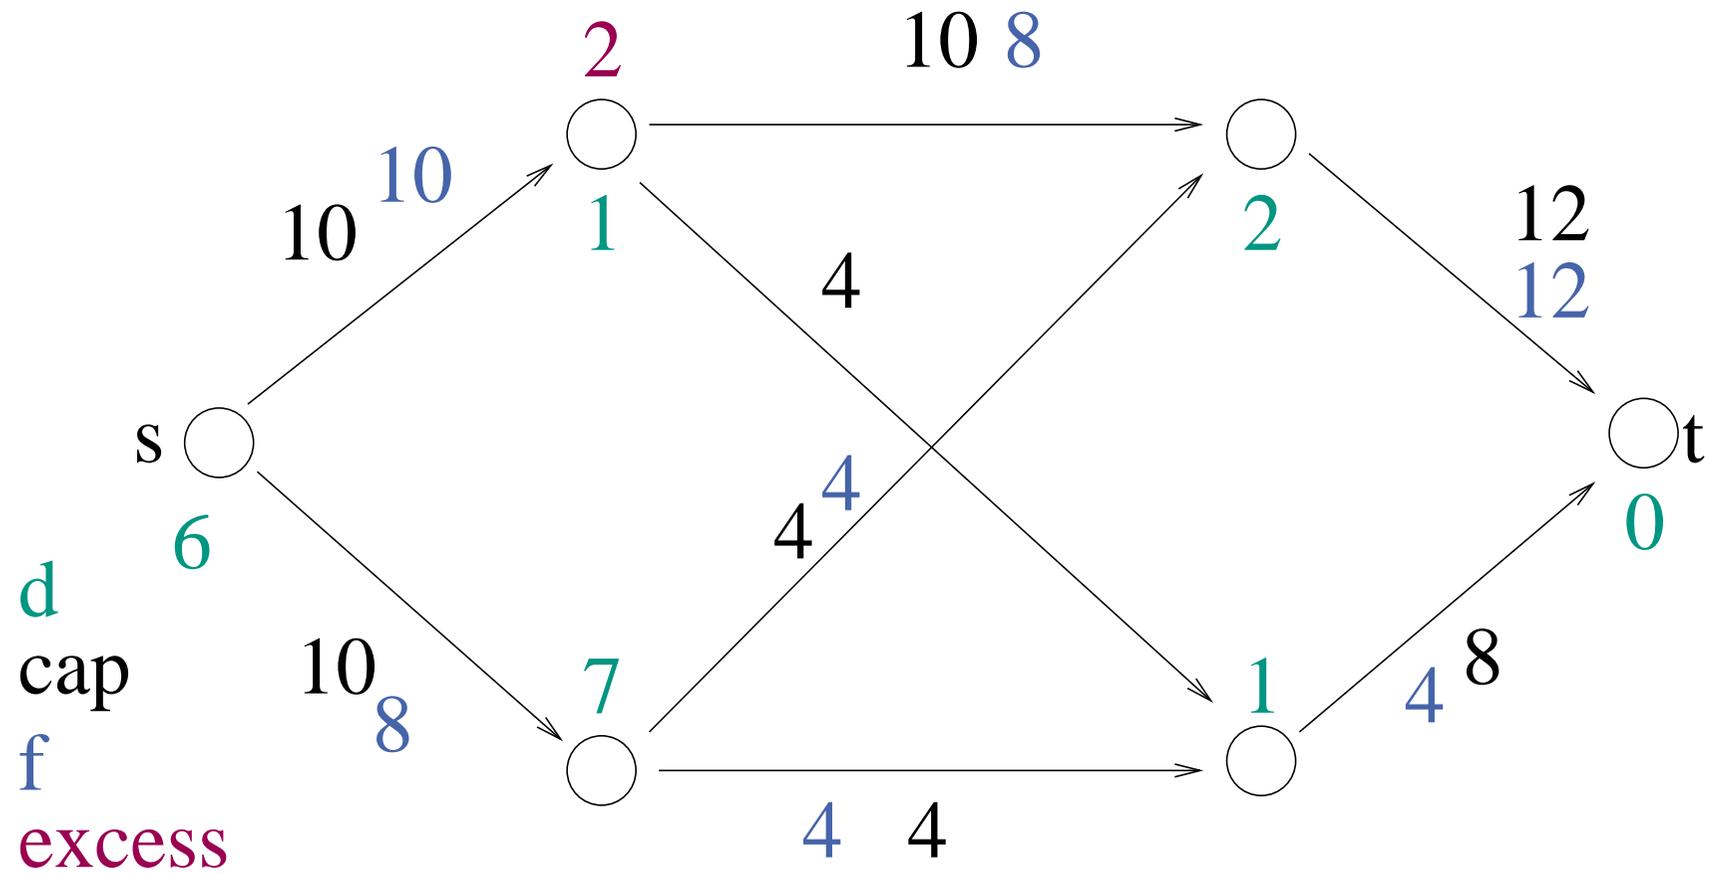
# Example



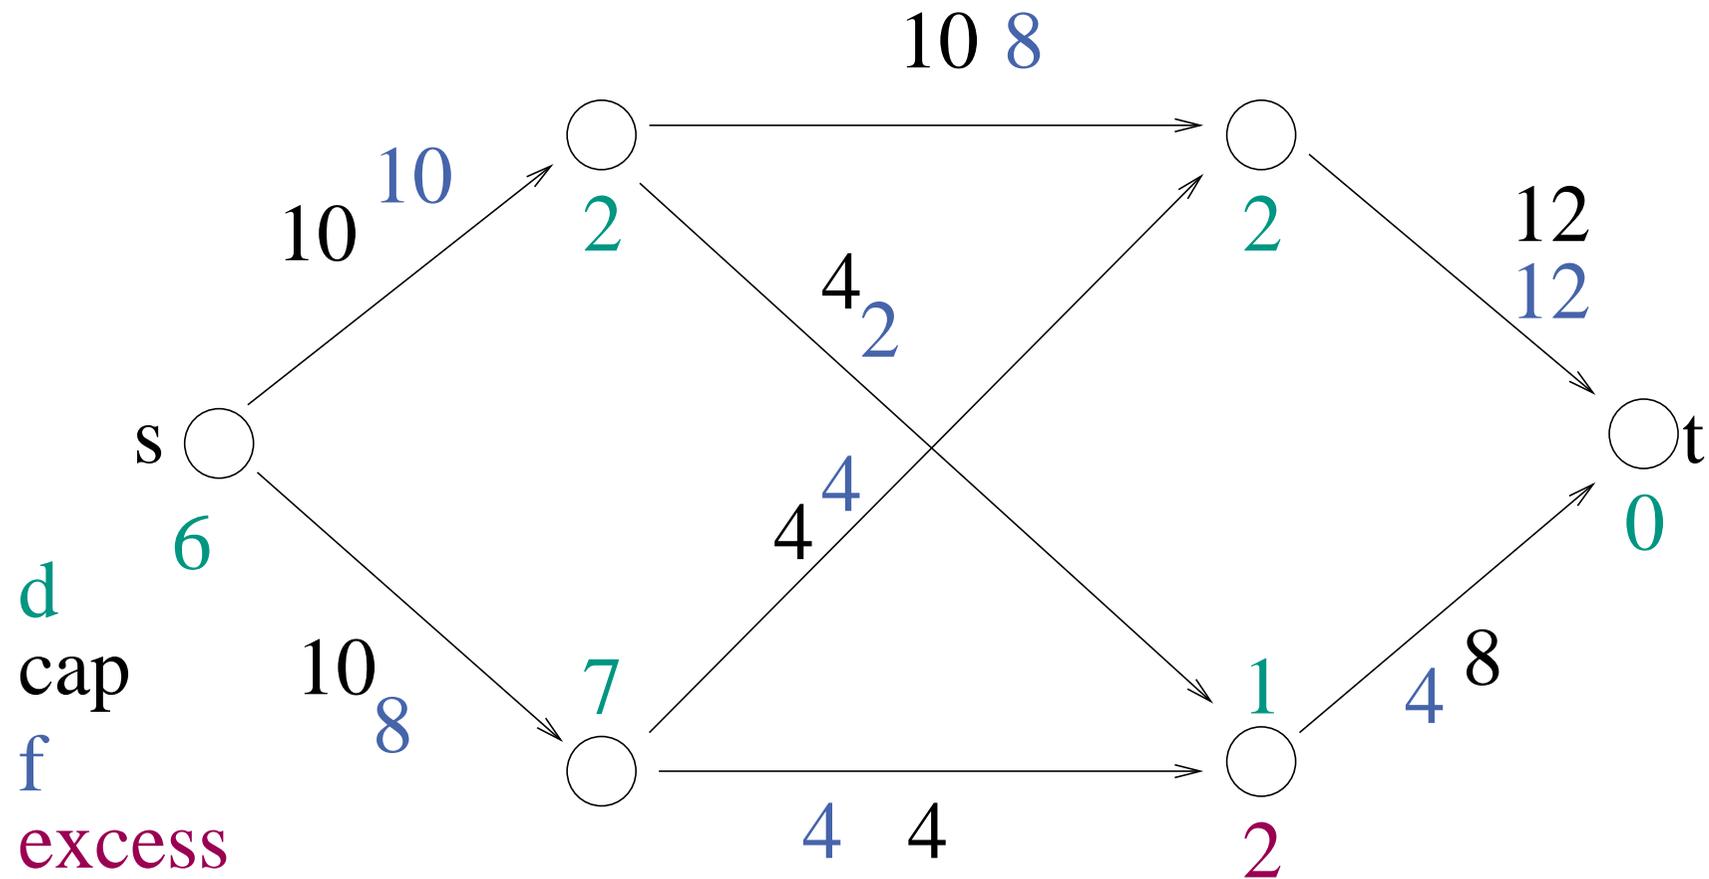
# Example



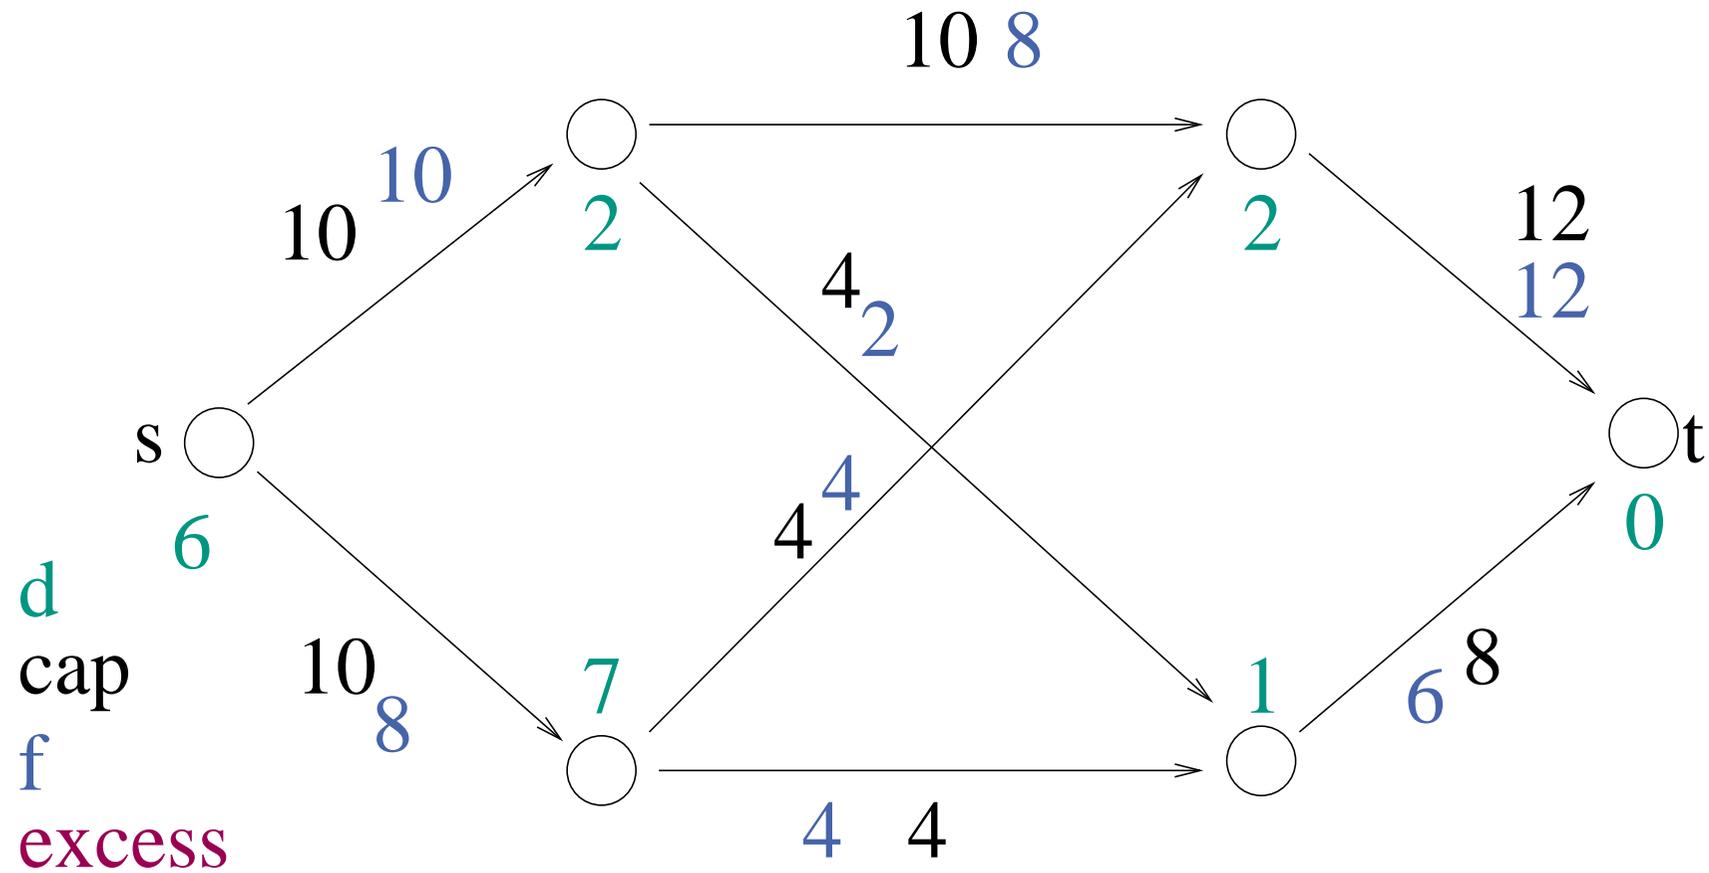
# Example



# Example



# Example



12 pushes in total

## Partial Correctness

**Lemma 3.** *When genericPreflowPush terminates  $f$  is a **maximal flow**.*

*Beweis.*

$f$  is a **flow** since  $\forall v \in V \setminus \{s, t\} : \text{excess}(v) = 0$ .

To show that  $f$  is **maximal**, it suffices to show that

$\nexists$  path  $p = \langle s, \dots, t \rangle \in G_f$  (Max-Flow Min-Cut Theorem):

Since  $d(s) = n$ ,  $d(t) = 0$ ,  $p$  would have to contain steep edges.

That would be a contradiction. □

**Lemma 4.** For any cut  $(S, T)$ ,

$$\sum_{u \in S} excess(u) = \sum_{e \in E \cap (T \times S)} f(e) - \sum_{e \in E \cap (S \times T)} f(e),$$

**Proof:**

$$\sum_{u \in S} excess(u) = \sum_{u \in S} \left( \sum_{(v, u) \in E} f((v, u)) - \sum_{(u, v) \in E} f((u, v)) \right)$$

Contributions of edge  $e$  to sum:

$S$  to  $T$ :  $-f(e)$

$T$  to  $S$ :  $f(e)$

within  $S$ :  $f(e) - f(e) = 0$

within  $T$ : 0



**Lemma 5.**

$\forall$  active nodes  $v$  :  $\text{excess}(v) > 0 \Rightarrow \exists$  path  $\langle v, \dots, s \rangle \in G_f$

Intuition: what got there can always go back.

*Beweis.*  $S := \{u \in V : \exists \text{ path } \langle v, \dots, u \rangle \in G_f\}$ ,  $T := V \setminus S$ . Then

$$\sum_{u \in S} \text{excess}(u) = \sum_{e \in E \cap (T \times S)} f(e) - \sum_{e \in E \cap (S \times T)} f(e),$$

$\forall (u, w) \in E_f : u \in S \Rightarrow w \in S$  by Def. of  $G_f$ ,  $S$

$\Rightarrow \forall e = (u, w) \in E \cap (T \times S) : f(e) = 0$  Otherwise  $(w, u) \in E_f$

Hence,  $\sum_{u \in S} \text{excess}(u) \leq 0$

Only the negative excess of  $s$  can outweigh  $\text{excess}(v) > 0$ .

Hence  $s \in S$ . □

**Lemma 6.**

$$\forall v \in V : d(v) < 2n$$

*Beweis.*

Suppose  $v$  is lifted to  $d(v) = 2n$ .

By the Lemma 2, there is a (simple) path  $p$  to  $s$  in  $G_f$ .

$p$  has at most  $n - 1$  nodes

$$d(s) = n.$$

Hence  $d(v) < 2n$ . Contradiction (no steep edges).



**Lemma 7.** # Relabel operations  $\leq 2n^2$

*Beweis.*  $d(v) \leq 2n$ , i.e.,  $v$  is relabeled at most  $2n$  times.

Hence, at most  $|V| \cdot 2n = 2n^2$  relabel operations. □

**Lemma 8.** # saturating pushes  $\leq nm$

*Beweis.*

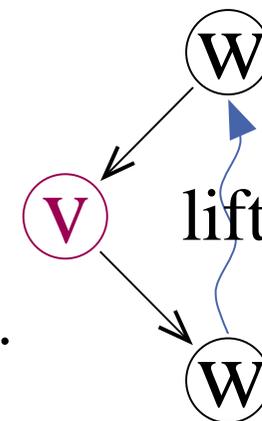
We show that there are **at most  $n$  sat. pushes** over any edge  $e = (v, w)$ .

A saturating push( $e, \delta$ ) **removes  $e$**  from  $E_f$ .

Only a **push on  $(w, v)$**  can **reinsert  $e$**  into  $E_f$ .

For this to happen,  $w$  must be **lifted** at least two levels.

Hence, at most  $2n/2 = n$  saturating pushes over  $(v, w)$



**Lemma 9.** # nonsaturating pushes =  $O(n^2m)$

if  $\delta = \min \left\{ \text{excess}(v), c_e^f \right\}$

for *arbitrary* node and edge selection rules.

(*arbitrary-preflow-push*)

*Beweis.*  $\Phi := \sum_{\{v:v \text{ is active}\}} d(v).$  (Potential)

$\Phi = 0$  initially **and** at the end (no active nodes left!)

Operation	$\Delta(\Phi)$	How many times?	Total effect
relabel	1	$\leq 2n^2$	$\leq 2n^2$
saturating push	$\leq 2n$	$\leq nm$	$\leq 2n^2m$
nonsaturating push	$\leq -1$		

$\Phi \geq 0$  always.



## Searching for Eligible Edges

Every node  $v$  maintains a **currentEdge** pointer to its sequence of outgoing edges in  $G_f$ .

**invariant** no edge  $e = (v, w)$  to the left of currentEdge is eligible

Reset currentEdge at a relabel ( $\leq 2n \times$ )

Invariant cannot be violated by a push over a reverse edge  $e' = (w, v)$

since this only happens when  $e'$  is downward,

i.e.,  $e$  is upward and hence not eligible.

**Lemma 10.**

*Total cost for searching*  $\leq \sum_{v \in V} 2n \cdot \text{degree}(v) = 4nm = \mathbf{O}(nm)$

**Satz 11.** *Arbitrary Preflow Push finds a maximum flow in time  $O(n^2m)$ .*

*Beweis.*

Lemma 3: partial correctness

Initialization in time  $O(n + m)$ .

Maintain set (e.g., stack, FIFO) of active nodes.

Use reverse edge pointers to implement push.

Lemma 7:  $2n^2$  relabel operations

Lemma 8:  $nm$  saturating pushes

Lemma 9:  $O(n^2m)$  nonsaturating pushes

Lemma 10:  $O(nm)$  search time for eligible edges

---

Total time  $O(n^2m)$



## **FIFO Preflow push**

**Examine a node:** Saturating pushes until nonsaturating push or relabel.

Examine all nodes in phases (or use FIFO queue).

**Theorem:** time  $O(n^3)$

**Proof:** not here

# Highest Level Preflow Push

Always select active nodes that **maximize**  $d(v)$

Use **bucket priority queue** (insert, increaseKey, deleteMax)

not monotone (!) but **relabels** “pay” for scan operations

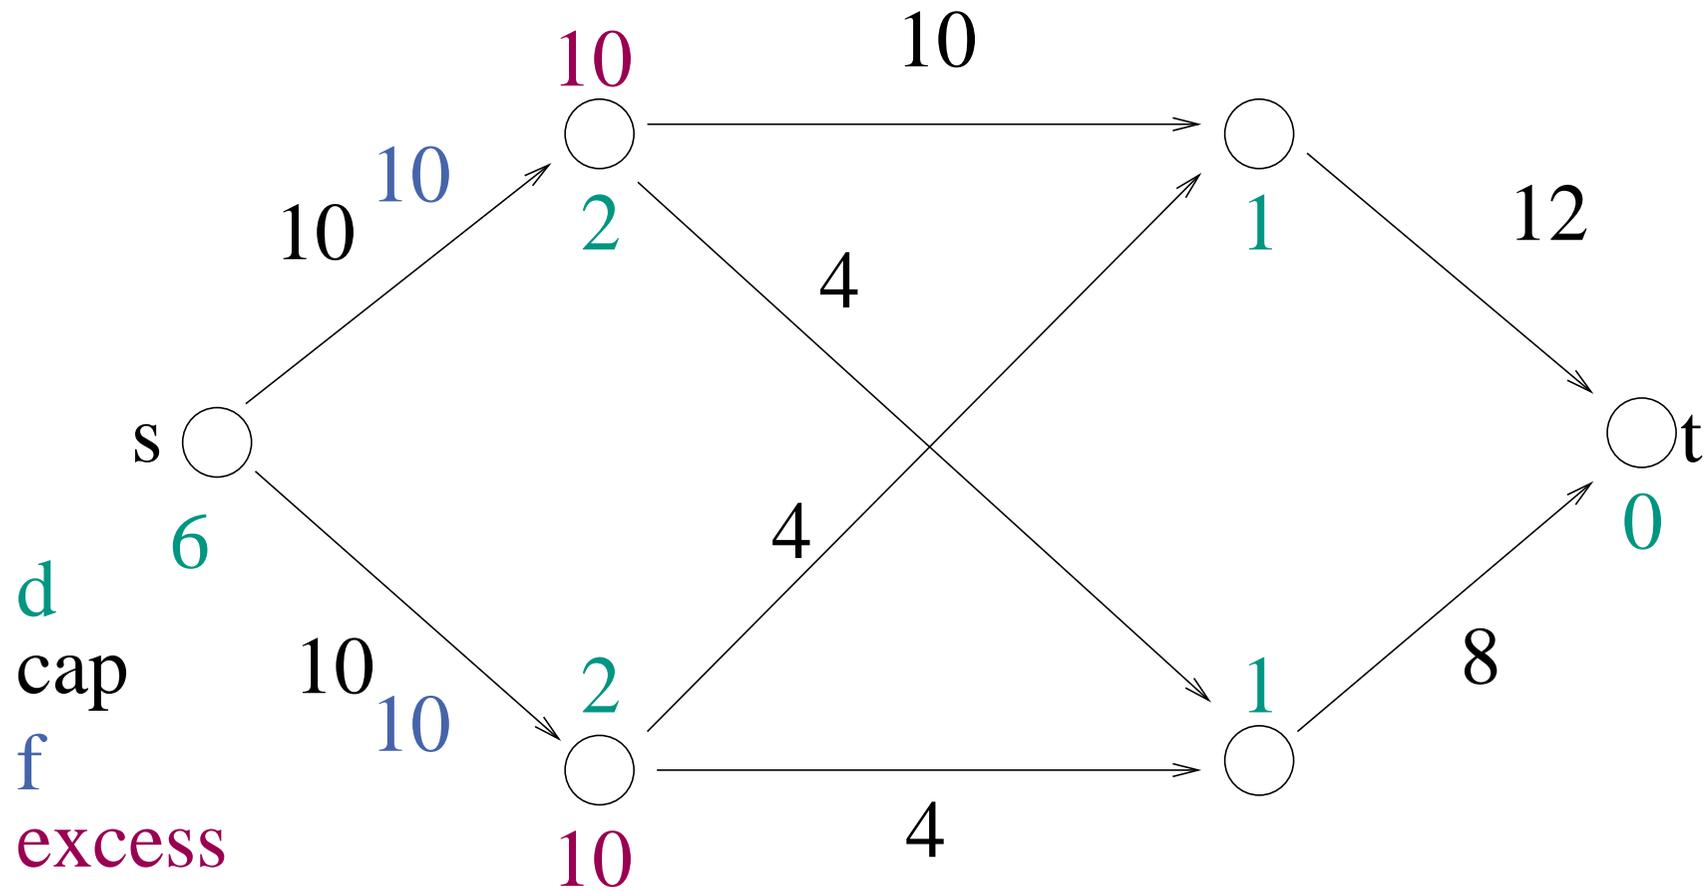
**Lemma 12.** *At most  $n^2\sqrt{m}$  nonsaturating pushes.*

*Beweis.* later

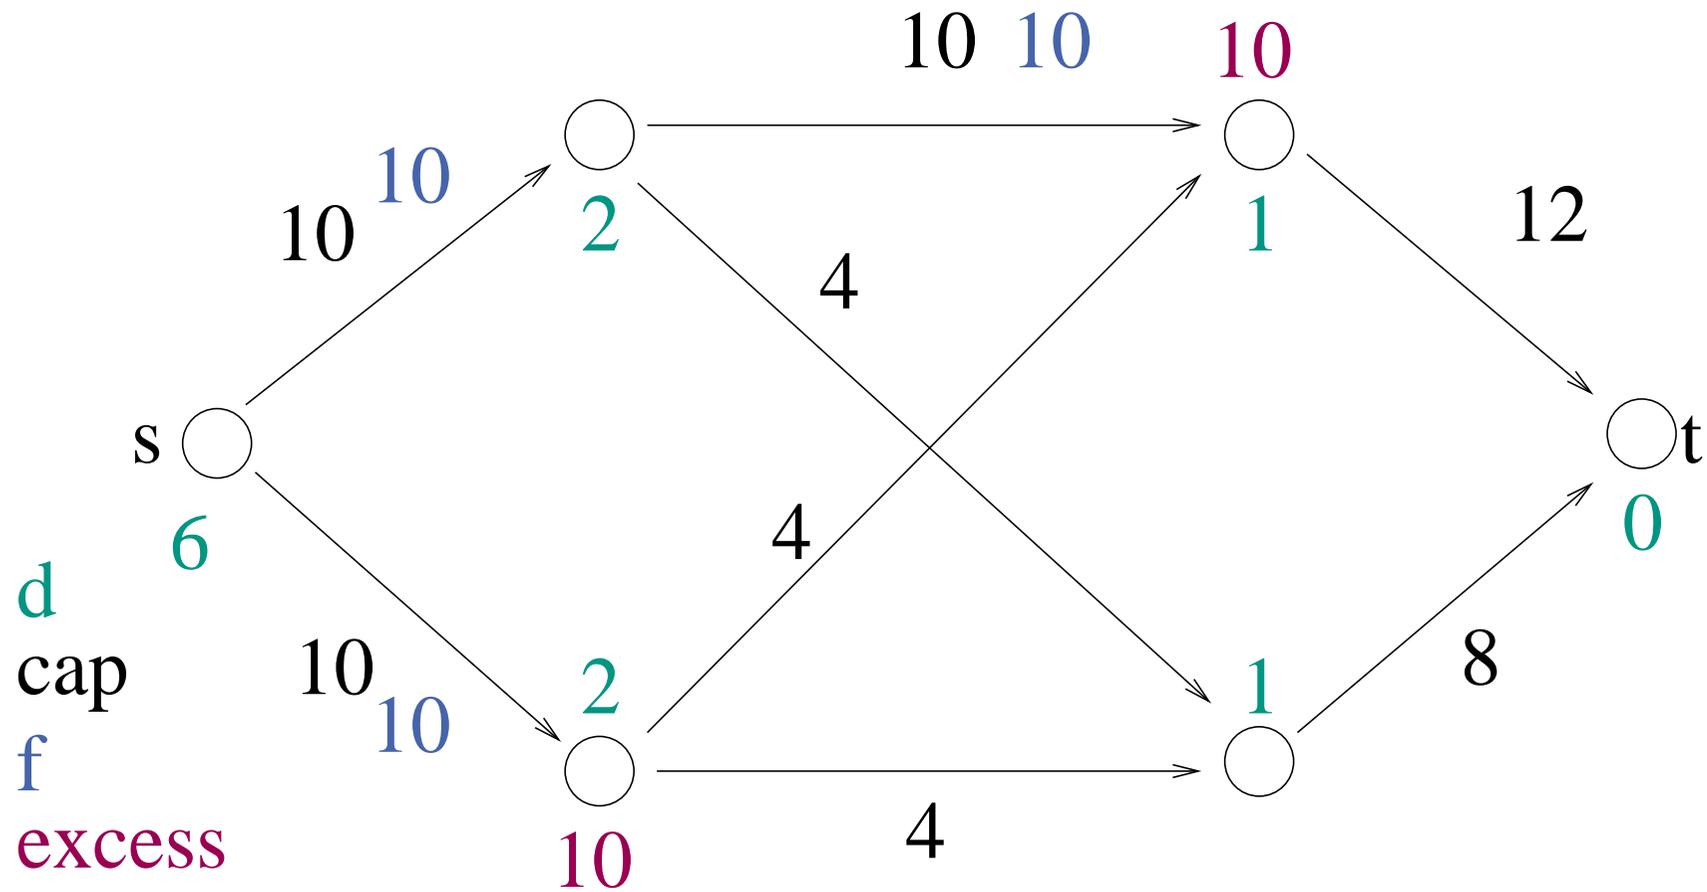


**Satz 13.** *Highest Level Preflow Push finds a maximum flow in time  $O(n^2\sqrt{m})$ .*

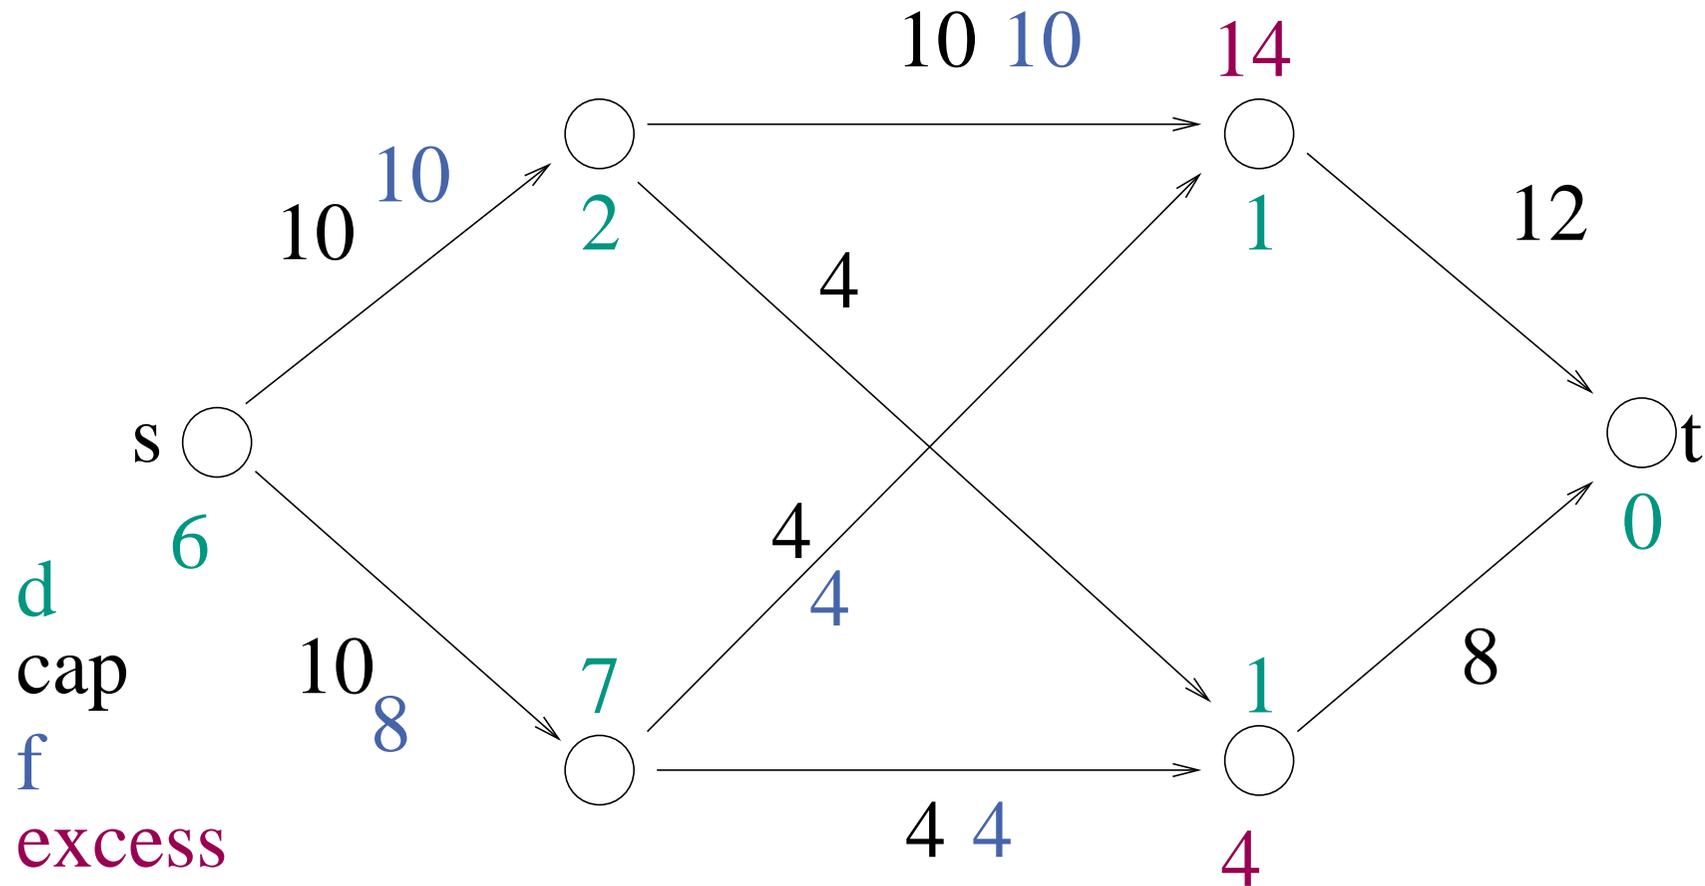
# Example



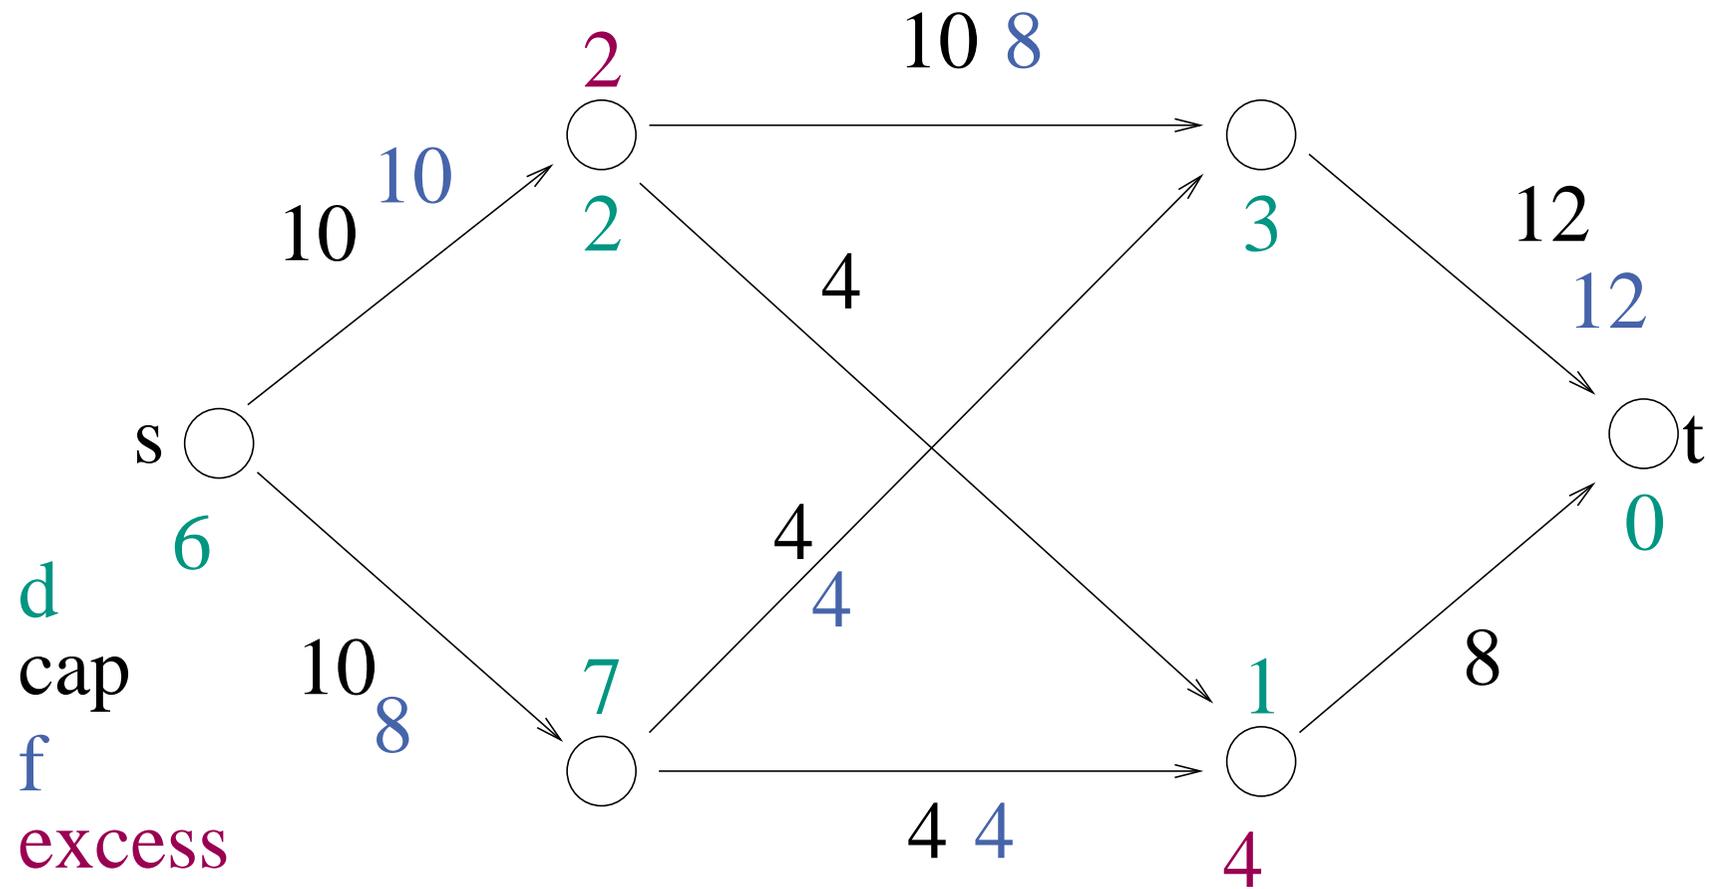
# Example



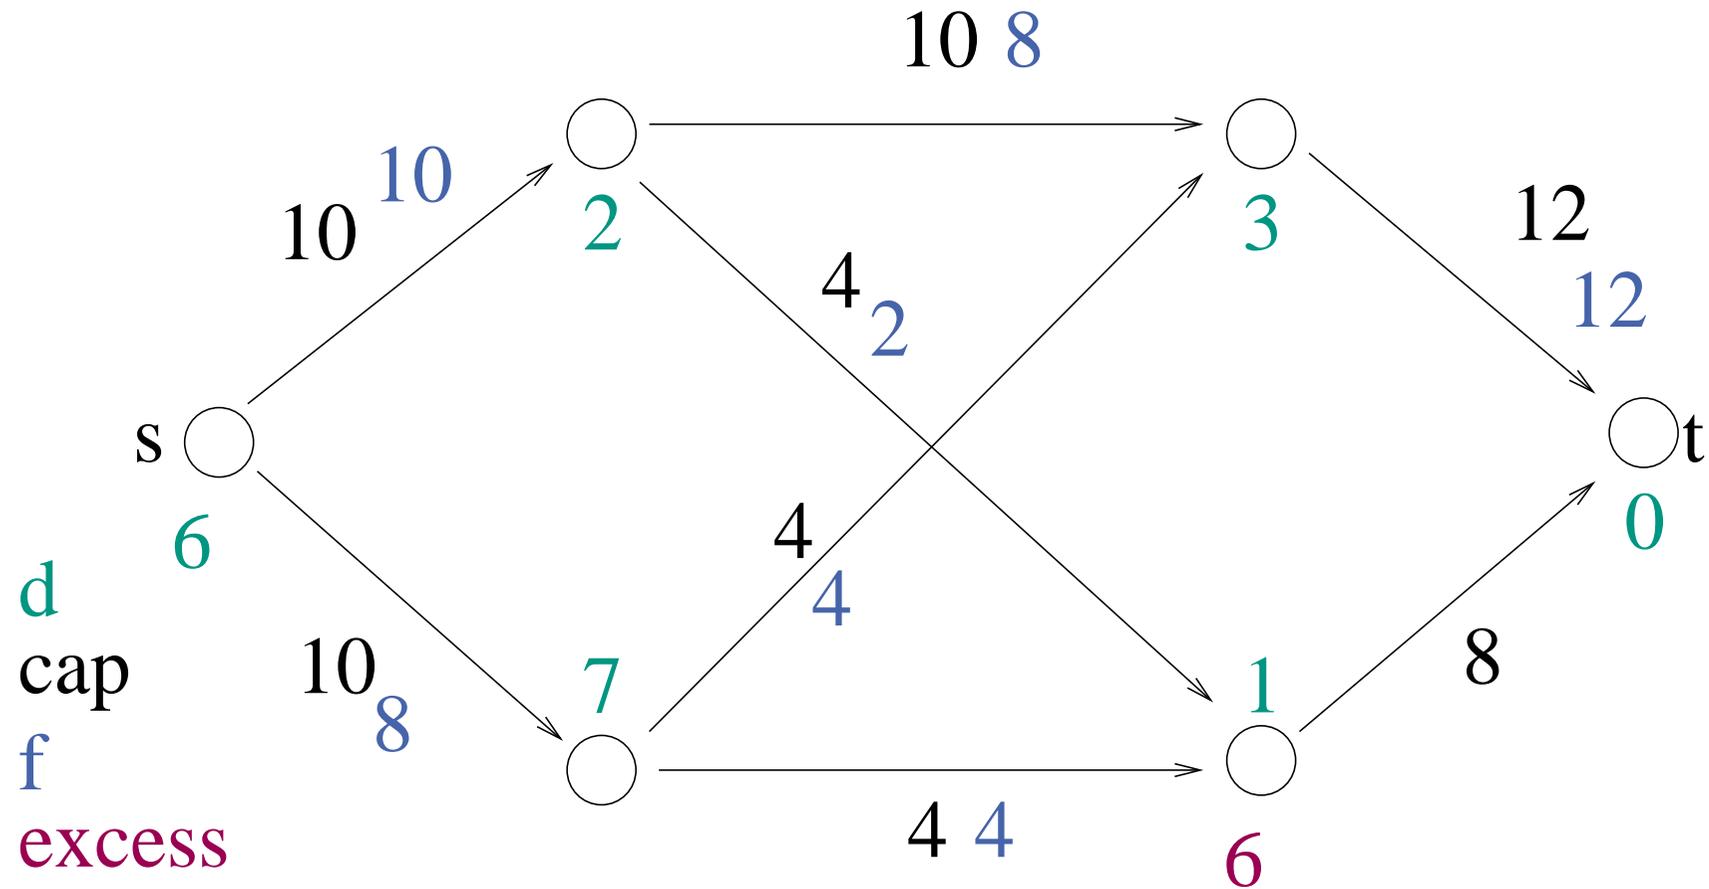
# Example



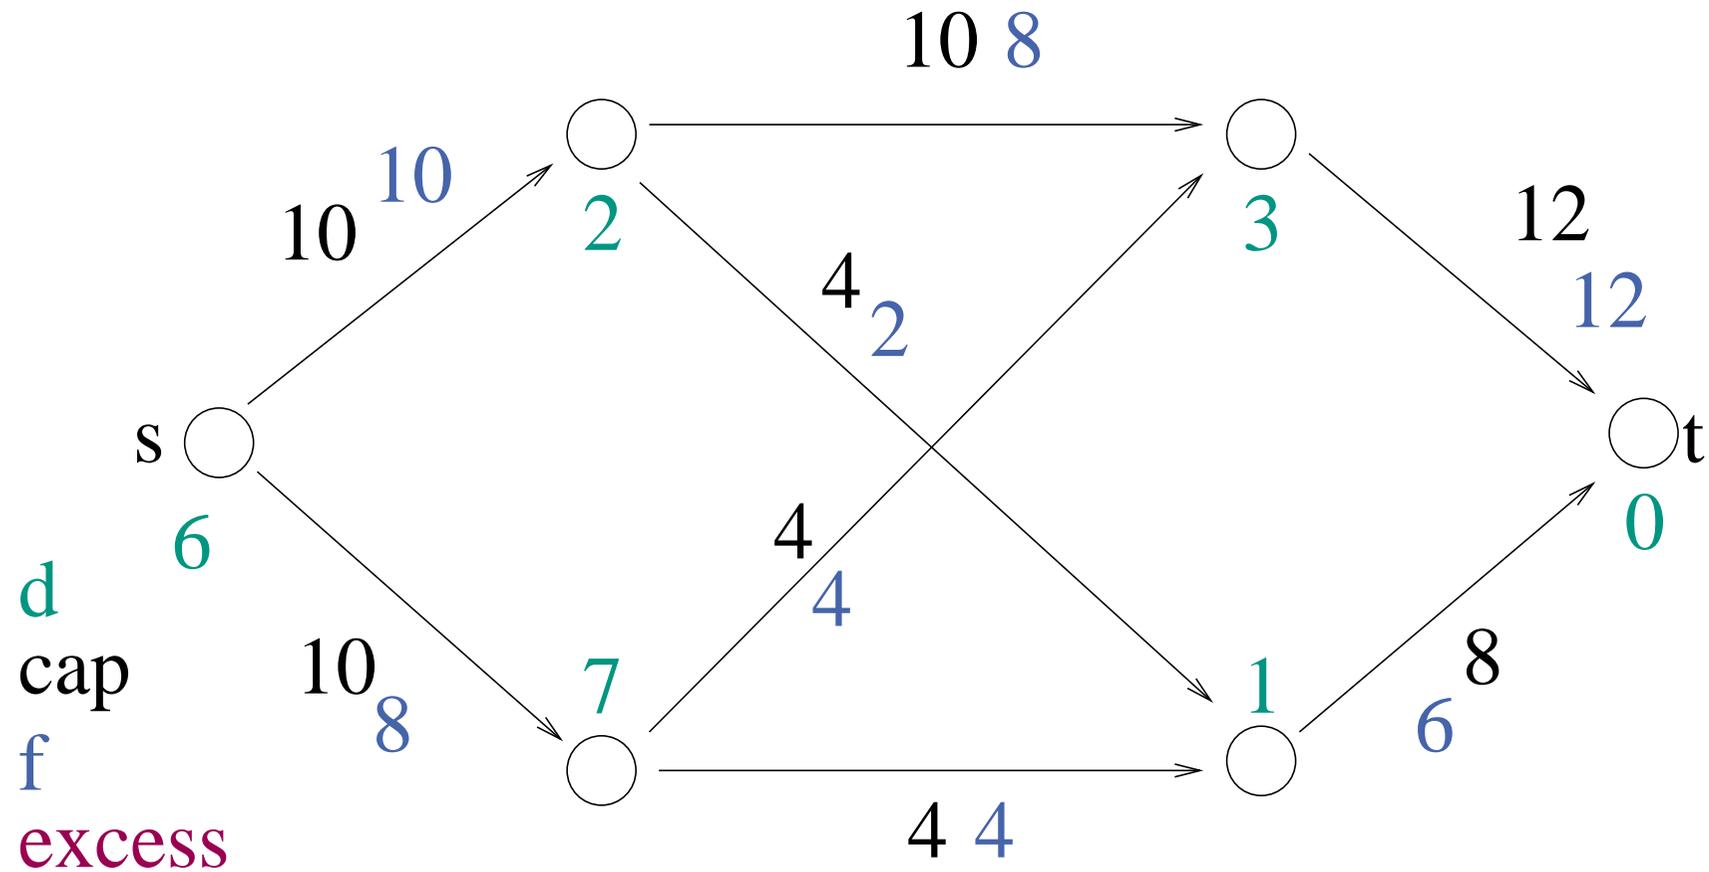
# Example



# Example



# Example



9 pushes in total, 3 less than before

## Proof of Lemma 12

$K := \sqrt{m}$  tuning parameter

$d'(v) := \frac{|\{w : d(w) \leq d(v)\}|}{K}$  scaled number of dominated nodes

$\Phi := \sum_{\{v:v \text{ is active}\}} d'(v).$  (Potential)

$d^* := \max \{d(v) : v \text{ is active}\}$  (highest level)

**phase**:= all pushes between two consecutive changes of  $d^*$

**expensive** phase: more than  $K$  pushes

**cheap** phase: otherwise

## Claims:

1.  $\leq 4n^2K$  nonsaturating pushes in all cheap phases together
2.  $\Phi \geq 0$  always,  $\Phi \leq n^2/K$  initially (obvious)
3. a relabel or saturating push increases  $\Phi$  by at most  $n/K$ .
4. a nonsaturating push does not increase  $\Phi$ .
5. an expensive phase with  $Q \geq K$  nonsaturating pushes decreases  $\Phi$  by at least  $Q$ .

Operation	Amount
Relabel	$2n^2$
Sat.push	$nm$

Lemma 7 + Lemma 8 + 2. + 3. + 4.  $\Rightarrow$

total possible decrease  $\leq (2n^2 + nm) \frac{n}{K} + \frac{n^2}{K}$

This + 5.  $\leq \frac{2n^3 + n^2 + mn^2}{K}$  nonsaturating pushes in expensive phases

This + 1.  $\leq \frac{2n^3 + n^2 + mn^2}{K} + 4n^2K = O(n^2 \sqrt{m})$  nonsaturating

pushes overall for  $K = \sqrt{m}$



## Claims:

1.  $\leq 4n^2 K$  nonsaturating pushes in all cheap phases together

We first show that there are at most  $4n^2$  phases

(changes of  $d^* = \max \{d(v) : v \text{ is active}\}$ ).

$d^* = 0$  initially,  $d^* \geq 0$  always.

Only **relabel** operations increase  $d^*$ , i.e.,

$\leq 2n^2$  increases by **Lemma 7** and hence

$\leq 2n^2$  decreases

---

$\leq 4n^2$  changes overall

By definition of a cheap phase, it has at most  $K$  pushes.

## Claims:

1.  $\leq 4n^2K$  nonsaturating pushes in all cheap phases together
2.  $\Phi \geq 0$  always,  $\Phi \leq n^2/K$  initially (obvious)
3. a relabel or saturating push increases  $\Phi$  by at most  $n/K$ .

Let  $v$  denote the relabeled or activated node.

$$d'(v) := \frac{|\{w : d(w) \leq d(v)\}|}{K} \leq \frac{n}{K}$$

A relabel of  $v$  can increase only the  $d'$ -value of  $v$ .

A saturating push on  $(u, w)$  may activate only  $w$ .

## Claims:

1.  $\leq 4n^2K$  nonsaturating pushes in all cheap phases together
2.  $\Phi \geq 0$  always,  $\Phi \leq n^2/K$  initially (obvious)
3. a relabel or saturating push increases  $\Phi$  by at most  $n/K$ .
4. a nonsaturating push does not increase  $\Phi$ .

$v$  is deactivated ( $\text{excess}(v)$  is now 0)

$w$  may be activated

but  $d'(w) \leq d'(v)$  (we do not push flow away from the sink)

## Claims:

1.  $\leq 4n^2K$  nonsaturating pushes in all cheap phases together
2.  $\Phi \geq 0$  always,  $\Phi \leq n^2/K$  initially (obvious)
3. a relabel or saturating push increases  $\Phi$  by at most  $n/K$ .
4. a nonsaturating push does not increase  $\Phi$ .
5. an expensive phase with  $Q \geq K$  nonsaturating pushes decreases  $\Phi$  by at least  $Q$ .

During a phase  $d^*$  remains constant

Each nonsat. push decreases the number of active nodes at level  $d^*$

Hence,  $|\{w : d(w) = d^*\}| \geq Q \geq K$  during an expensive phase

Each nonsat. push across  $(v, w)$  decreases  $\Phi$  by

$$\geq d'(v) - d'(w) \geq |\{w : d(w) = d^*\}| / K \geq K / K = 1$$



## Claims:

1.  $\leq 4n^2K$  nonsaturating pushes in all cheap phases together
2.  $\Phi \geq 0$  always,  $\Phi \leq n^2/K$  initially (obvious)
3. a relabel or saturating push increases  $\Phi$  by at most  $n/K$ .
4. a nonsaturating push does not increase  $\Phi$ .
5. an expensive phase with  $Q \geq K$  nonsaturating pushes decreases  $\Phi$  by at least  $Q$ .

Operation	Amount
Relabel	$2n^2$
Sat.push	$nm$

Lemma 7 + Lemma 8 + 2. + 3. + 4.  $\Rightarrow$

total possible decrease  $\leq (2n^2 + nm) \frac{n}{K} + \frac{n^2}{K}$

This + 5.  $\leq \frac{2n^3 + n^2 + mn^2}{K}$  nonsaturating pushes in expensive phases

This + 1.  $\leq \frac{2n^3 + n^2 + mn^2}{K} + 4n^2K = O(n^2 \sqrt{m})$  nonsaturating

pushes overall for  $K = \sqrt{m}$



## **MFIFO: Modified FIFO Selection Rule**

pushFront after relabel.

pushBack when activated by a push N

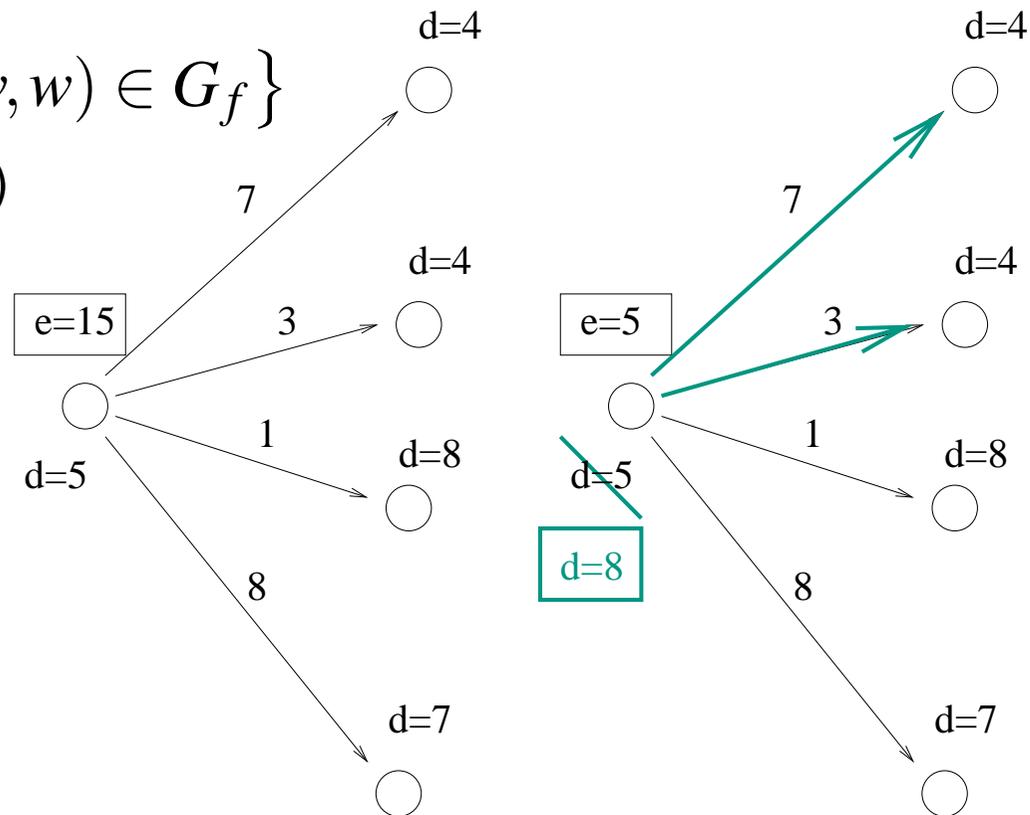
# Heuristic Improvements

Naive algorithm has needs  $\Omega(n^2)$  even on a path graph. We can do better.

aggressive local relabeling:

$$d(v) := 1 + \min \{ d(w) : (v, w) \in G_f \}$$

(like a sequence of relabels)



# Heuristic Improvements

Naive algorithm has **best case**  $\Omega(n^2)$ . Why? We can do better.

**aggressive local relabeling**:  $d(v) := 1 + \min \{d(w) : (v, w) \in G_f\}$

(like a sequence of relabels)

**global relabeling**: (initially and every  $O(m)$  edge inspections):

$d(v) := G_f.\text{reverseBFS}(t)$  for nodes that can reach  $t$  in  $G_f$ .

Special treatment of nodes with  $d(v) \geq n$ . (**Returning flow** is easy)

**Gap Heuristics**. No node can connect to  $t$  across an empty level:

**if**  $\{v : d(v) = i\} = \emptyset$  **then foreach**  $v$  with  $d(v) > i$  **do**  $d(v) := n$

# Experimental results

We use four classes of graphs:

- Random:  $n$  nodes,  $2n + m$  edges; all edges  $(s, v)$  and  $(v, t)$  exist
- Cherkassky and Goldberg (1997) (two graph classes)
- Ahuja, Magnanti, Orlin (1993)

## Timings: Random Graphs

Rule	BASIC	Ln	LRH	GRH	GAP	LEDA
FF	5.84	6.02	4.75	0.07	0.07	—
	33.32	33.88	26.63	0.16	0.17	—
HL	6.12	6.3	4.97	0.41	0.11	0.07
	27.03	27.61	22.22	1.14	0.22	0.16
MF	5.36	5.51	4.57	0.06	0.07	—
	26.35	27.16	23.65	0.19	0.16	—

$n \in \{1000, 2000\}, m = 3n$

FF=FIFO node selection, HL=highest level, MF=modified FIFO

Ln =  $d(v) \geq n$  is special,

LRH=local relabeling heuristic, GRH=global relabeling heuristics

## Timings: CG1

Rule	BASIC	Ln	LRH	GRH	GAP	LEDA
FF	3.46	3.62	2.87	<b>0.9</b>	1.01	—
	15.44	16.08	12.63	3.64	4.07	—
HL	20.43	20.61	20.51	1.19	1.33	<b>0.8</b>
	192.8	191.5	193.7	4.87	5.34	3.28
MF	3.01	3.16	2.3	<b>0.89</b>	1.01	—
	12.22	12.91	9.52	3.65	4.12	—

$n \in \{1000, 2000\}, m = 3n$

FF=FIFO node selection, HL=highest level, MF=modified FIFO

Ln =  $d(v) \geq n$  is special,

LRH=local relabeling heuristic, GRH=global relabeling heuristics

## Timings: CG2

Rule	BASIC	Ln	LRH	GRH	GAP	LEDA
FF	50.06	47.12	37.58	1.76	1.96	—
	239	222.4	177.1	7.18	8	—
HL	42.95	41.5	30.1	0.17	0.14	<b>0.08</b>
	173.9	167.9	120.5	0.36	0.28	0.18
MF	45.34	42.73	37.6	0.94	1.07	—
	198.2	186.8	165.7	4.11	4.55	—

$n \in \{1000, 2000\}, m = 3n$

FF=FIFO node selection, HL=highest level, MF=modified FIFO

Ln =  $d(v) \geq n$  is special,

LRH=local relabeling heuristic, GRH=global relabeling heuristics

## Timings: AMO

Rule	BASIC	Ln	LRH	GRH	GAP	LEDA
FF	12.61	13.25	1.17	<b>0.06</b>	<b>0.06</b>	—
	55.74	58.31	5.01	0.1399	0.1301	—
HL	15.14	15.8	1.49	0.13	0.13	<b>0.07</b>
	62.15	65.3	6.99	0.26	0.26	0.14
MF	10.97	11.65	0.04999	<b>0.06</b>	<b>0.06</b>	—
	46.74	49.48	0.1099	0.1301	0.1399	—

$n \in \{1000, 2000\}, m = 3n$

FF=FIFO node selection, HL=highest level, MF=modified FIFO

Ln =  $d(v) \geq n$  is special,

LRH=local relabeling heuristic, GRH=global relabeling heuristics

## Asymptotics, $n \in \{5000, 10000, 20000\}$

Gen	Rule	GRH			GAP			LEDA		
rand	FF	0.16	0.41	1.16	0.15	0.42	1.05	—	—	—
	HL	1.47	4.67	18.81	0.23	0.57	1.38	0.16	0.45	1.09
	MF	0.17	0.36	1.06	0.14	0.37	<b>0.92</b>	—	—	—
CG1	FF	3.6	16.06	69.3	3.62	16.97	71.29	—	—	—
	HL	4.27	20.4	77.5	4.6	20.54	80.99	2.64	12.13	<b>48.52</b>
	MF	3.55	15.97	68.45	3.66	16.5	70.23	—	—	—
CG2	FF	6.8	29.12	125.3	7.04	29.5	127.6	—	—	—
	HL	0.33	0.65	1.36	0.26	0.52	1.05	0.15	0.3	<b>0.63</b>
	MF	3.86	15.96	68.42	3.9	16.14	70.07	—	—	—
AMO	FF	0.12	0.22	0.48	0.11	0.24	0.49	—	—	—
	HL	0.25	0.48	0.99	0.24	0.48	0.99	0.12	0.24	0.52
	MF	0.11	0.24	0.5	0.11	0.24	0.48	—	—	—

## Recent AE Results on Max-Flow

Faster and More Dynamic Maximum Flow by Incremental Breadth-First Search, Goldberg, Hed, Kaplan, Kohli, Tarjan, Werneck, ESA 2015

- Much **faster** on many (relatively easy) **real world** instances (image processing, graph partitioning, . . . ) than preflow-push
- Worst case performance guarantee  $O(mn^2)$  (as in Dinitz algorithm)
- Adaptable to **dynamic** scenarios
- Uses **pseudoflows** that allow excesses and **deficits**.

Open problem: close gaps between theory and practice!

# Zusammenfassung Flows und Matchings

- Natürliche Verallgemeinerung von kürzesten Wegen:  
ein Pfad  $\rightsquigarrow$  viele Pfade
- viele Anwendungen
- “schwierigste/allgemeinste” Graph-Probleme, die sich mit  
**kombinatorischen** Algorithmen in **Polynomialzeit** lösen lassen
- Beispiel für nichttriviale Algorithmenanalyse
- Potentialmethode** ( $\neq$  **Knoten**potentiale)
- Algorithm Engineering: practical case  $\neq$  worst case.  
**Heuristiken/Details/Eingabeeigenschaften** wichtig
- Datenstrukturen: bucket queues, graph representation, (dynamic trees)

# 6 Randomisierte Algorithmen

verwende Zufall(sbits) zur Beschleunigung/Vereinfachung von Algorithmen

**Las Vegas:** Ergebnis immer korrekt, Laufzeit ist Zufallsvariable.

Schon gesehen:

quicksort

hashing

**Monte Carlo:** Ergebnis mit bestimmter Wahrscheinlichkeit  $p$  inkorrekt.

$k$ -fache Wiederholung macht Fehlschlagswahrscheinlichkeit exponentiell klein ( $p^k$ ).

Mehr in der Vorlesung Randomisierte Algorithmen von Thomas Worsch

## 6.1 Sortieren – Ergebnisüberprüfung (Checking)

**Permutationseigenschaft** (Sortiertheit: trivial.)

$\langle e_1, \dots, e_n \rangle$  ist Permutation von  $\langle e'_1, \dots, e'_n \rangle$  gdw.

$$q(z) := \prod_{i=1}^n (z - \text{field}(\text{key}(e_i))) - \prod_{i=1}^n (z - \text{field}(\text{key}(e'_i))) = 0,$$

$\mathbb{F}$  sei Körper,  $\text{field} : \text{Key} \rightarrow \mathbb{F}$  sei injektiv.

Beobachtung:  $q$  hat höchstens  $n$  Nullstellen.

Auswertung an zufälliger Stelle  $x \in \mathbb{F}$ .

$$\mathbb{P}[q \neq 0 \wedge q(x) = 0] \leq \frac{n}{|\mathbb{F}|}$$

Monte Carlo-Algorithmus, Linearzeit.

Frage: Welchen Körper  $\mathbb{F}$  nehmen wir?

## Sort Checking II – mit Lorenz Hübschle-Schneider

Ist Folge  $E$  eine Permutation von Folge  $E'$ ?

Sei  $h$  zufällige Hash-Funktion mit Wertebereich  $0..U - 1$ ,

$$h(S) := \sum_{e \in S} h(e)$$

**Checker:** return  $h(E) = h(E')$

## Sort Checking II – mit Lorenz Hübschle-Schneider

Ist Folge  $E$  eine Permutation von Folge  $E'$ ?

Sei  $h$  zufällige Hash-Funktion mit Wertebereich  $0..U - 1$ ,

$$h(S) := \sum_{e \in S} h(e)$$

**Checker:** return  $h(E) = h(E')$

Korrekt falls  $E = E'$ .

**Fall  $E \neq E'$ :** Wir zeigen  $\mathbb{P}[h(E) = h(E')] \leq \frac{1}{U}$

Sei  $e$  ein Element, das  $k \times$  in  $E$  vorkommt und  $k' \neq k \times$  in  $E'$ .

$$h(E) = h(E') \Leftrightarrow h(E \setminus e) + kh(e) = h(E' \setminus e) + k'h(e)$$

$$\Leftrightarrow h(e) = \frac{h(E' \setminus e) - h(E \setminus e)}{k - k'} =: x$$

$\mathbb{P}[h(e) = x] \leq \frac{1}{U}$  weil  $x$  unabhängig von  $h(e)$  ■

## 6.2 Hashing II

### Perfektes Hashing

Idee: mache  $h$  injektiv.

Braucht  $\Omega(n)$  bits Platz !

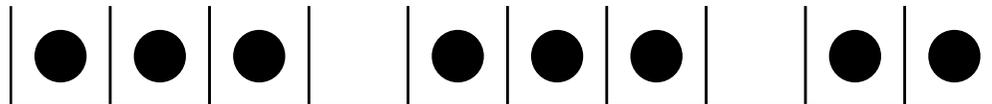
## Here: Fast Space Efficient Hashing

Represent a set of  $n$  elements (with associated information) using space  $(1 + \epsilon)n$ .

Support operations **insert**, **delete**, **lookup**, (doall) efficiently.

Assume a truly random hash function  $h$

(Trick [Dietzfelbinger, Weidling 2005]: läßt sich rechtfertigen.)



# Related Work

Linear probing:  $E[T_{\text{find}}] \approx \frac{1}{2\varepsilon^2}$

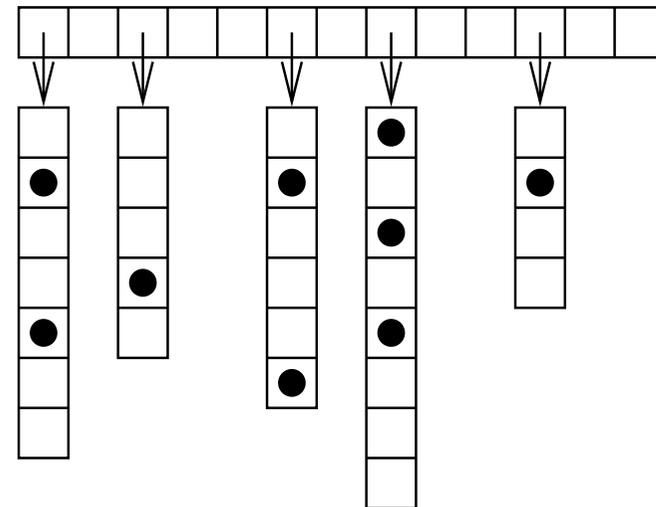
Uniform hashing:  $E[T_{\text{find}}] \approx \frac{1}{\varepsilon}$

Dynamic Perfect Hashing,

[Dietzfelbinger et al. 94]

Worst case constant time

for lookup but  $\varepsilon$  is not small.



Approaching the Information Theoretic Lower Bound:

[Brodnik Munro 99, Raman Rao 02]

Space  $(1 + o(1)) \times$  lower bound without associated information

[Botelho Pagh Ziviani 2007] static case.

Simple, fast,  $\approx 3$ bits/element [FiRe/FiPha: Müller, S, Schulze, Zhou 14]

# Cuckoo Hashing

[Pagh Rodler 01]

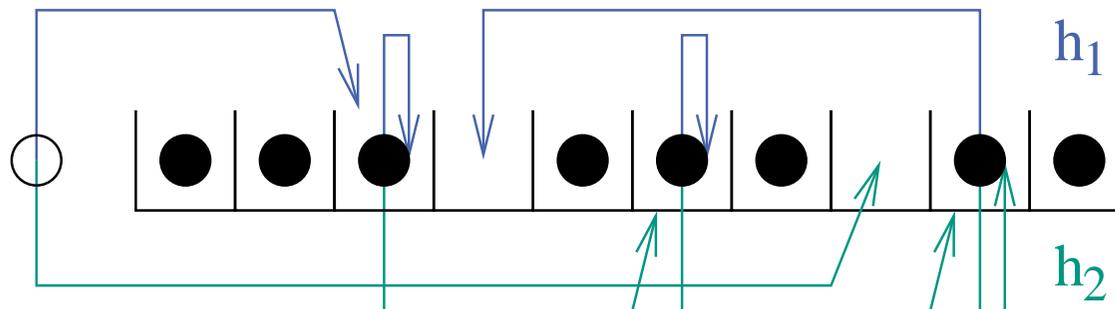
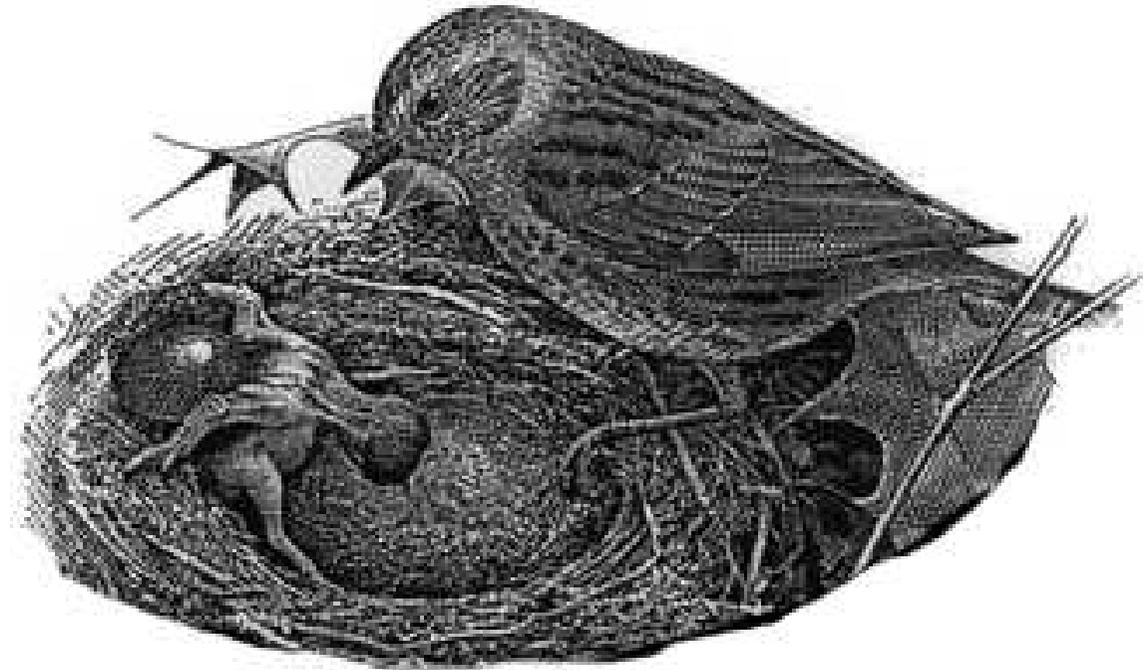
Table of size  $(2 + \epsilon)n$ .

**Two** choices for each element.

Insert moves elements;  
rebuild if necessary.

Very fast lookup and delete.

Expected constant insertion time.



# Cuckoo Hashing – Rebuilds

When needed ?

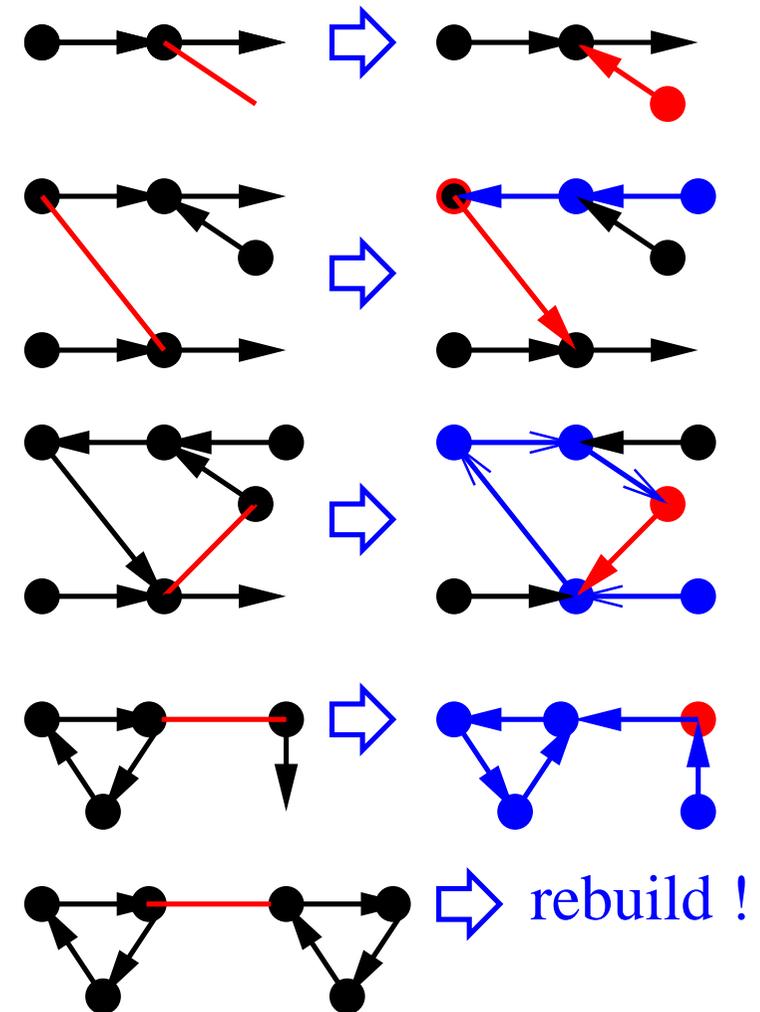
Graph model.

node: table cells

undirected edge: element  $x \rightsquigarrow$   
edge  $\{h_1(x), h_2(x)\}$

directed:  $(h_2(x), h_1(x))$  means  
element  $x$  is stored at cell  $h_2(x)$

**Lemma:** insert( $x$ ) succeeds iff  
the component containing  $h_1(x), h_2(x)$   
contains no more edges than nodes.



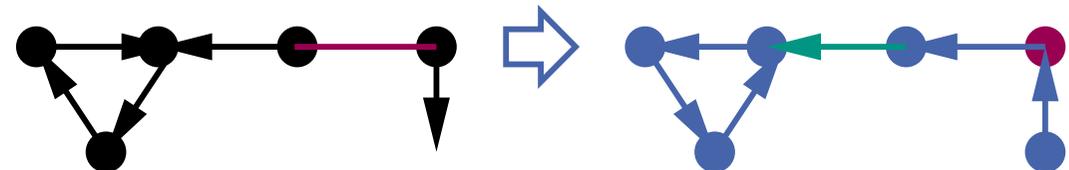
# Cuckoo Hashing – Rebuilds

**Lemma:**  $\text{insert}(x)$  succeeds iff  
the component containing  $h_1(x), h_2(x)$   
contains no more edges than nodes.

**Proof outline:** (if-part)

$h_1(x)$  in tree: flip path to root

$h_1(x)$  in pseudotree  $p$ ,  $h_2(x)$  in tree  $t$ :  
flip cycle and path to root in  $t$



# Cuckoo Hashing – How Many Rebuilds?

**Theorem:** For truly random hash functions,

$$\Pr[\text{rebuild necessary}] = O(1/n)$$

**Proof:** via random graph theory

# Random Graph Theory

[Erdős, Rényi 1959]

$\mathcal{G}(n, m)$  := sample space of all graphs with  $n$  nodes,  $m$  edges.

A random graph from  $\mathcal{G}(n, m)$  has certain properties **with high probability**, here  $\geq 1 - O(1/n)$ .

Famous: The evolution of component sizes with increasing  $m$ :

$< (1 - \varepsilon)n/2$ : **Trees and Pseudotrees of size  $O(\log n)$**

$> (1 + \varepsilon)n/2$ : A “giant” component of size  $\Theta(n)$  (sudden emergence)

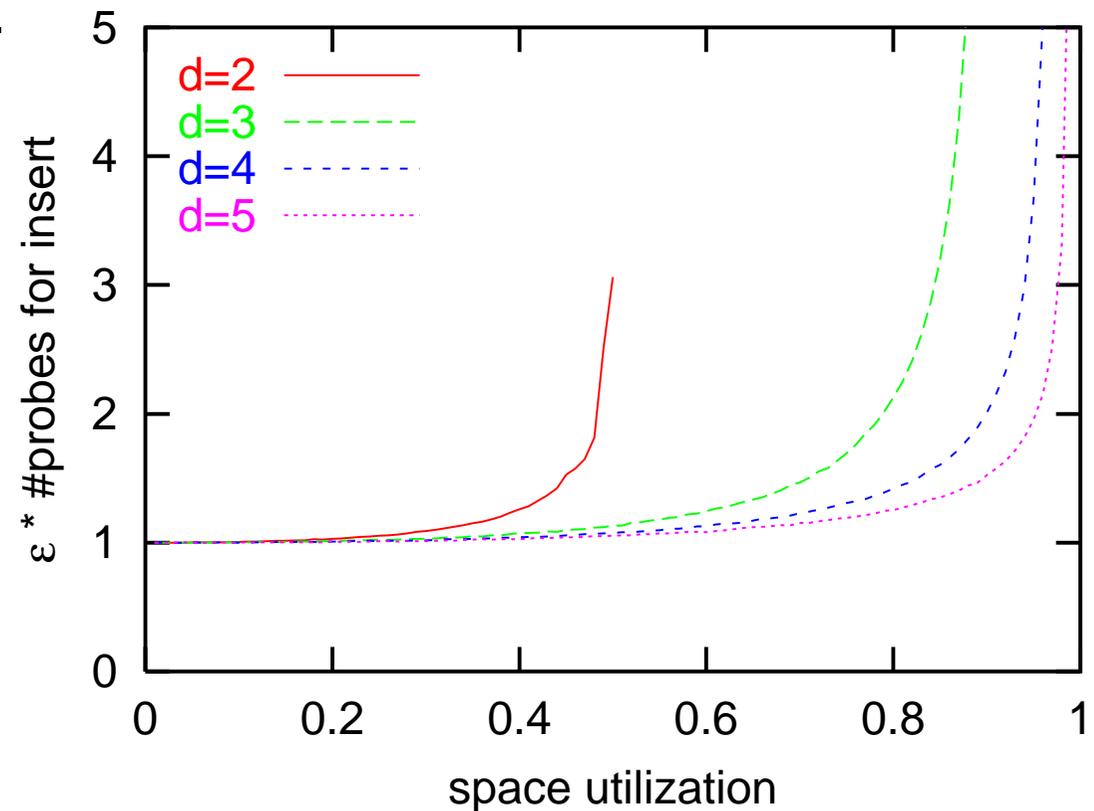
$> (1 + \varepsilon)n \ln n/2$ : One single component

# Space Efficient Cuckoo Hashing

***d*-ary:** [Fotakis, Pagh, Sanders, Spirakis 2003] *d* possible places.

**Insertion:** BFS, random walk, ...

expected time:  $O\left(\frac{1}{\varepsilon}\right)$  ?



# Space Efficient Cuckoo Hashing

***d*-ary:** [Fotakis, Pagh, Sanders, Spirakis 2003]  $d$  possible places.

**blocked:** [Dietzfelbinger, Weidling 2005] cells house  $d$  elements.

Cache efficient !

**blocked, *d*-ary, dynamic growing:**

[Maier, Sanders 2017]

# Zusammenfassung: Randomisierte Algorithmen

- einfache, effiziente Algorithmen
- oft bestes bekanntes Verfahren
- z.T. Unmöglichkeitsbeweise für deterministische Verfahren
- Analyse oft nichttrivial
- z.T. wird aus esoterischer Theorie ein praxisrelevantes Werkzeug,  
z.B. random graph evolution
- Las Vegas versus Monte Carlo
- Brücke zur Algebra: z.B. Checker für Sortieren

# Ausblick: Randomisierte Algorithmen

- externe minimale Spannbäume
- mehr quicksort (strings, parallel)
- kleinster umschließender Kreis
- online paging

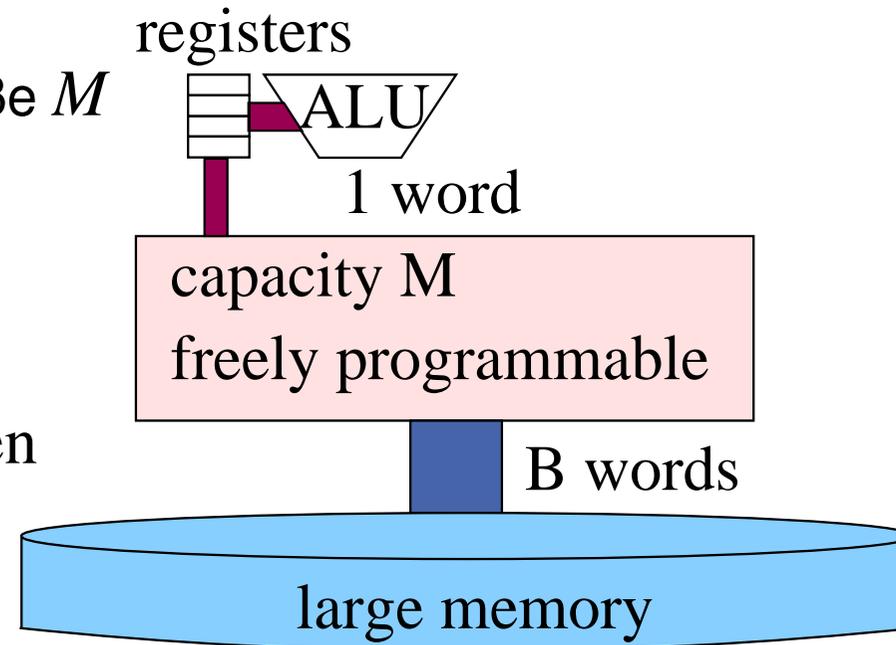
# 7 Externe Algorithmen

## 7.1 Das Sekundärspeichermodell

$M$ : Schneller Speicher der Größe  $M$

$B$ : Blockgröße

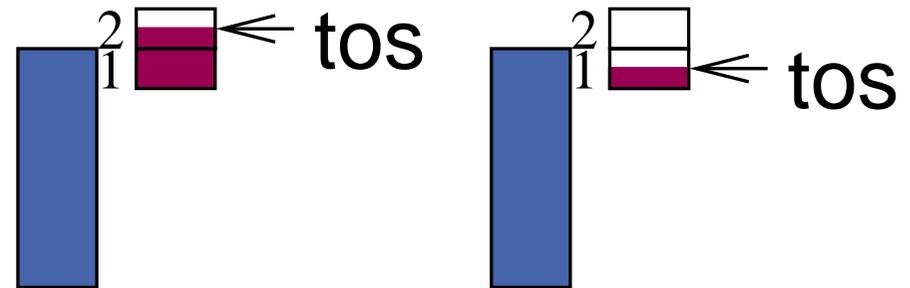
**Analyse:** Blockzugriffe zählen



## 7.2 Externe Stapel

Datei mit Blöcken

2 interne Puffer



**push:** Falls Platz, in Puffer.

Sonst schreibe Puffer **eins** in die Datei (push auf Blockebene)

Umbenennung: Puffer 1 und 2 tauschen die Plätze

**pop:** Falls vorhanden, pop aus Puffer.

Sonst lese Puffer **eins** aus der Datei (pop auf Blockebene)

Analyse: amortisiert  $O(1/B)$  I/Os pro Operation

Aufgabe 1: Beweis.

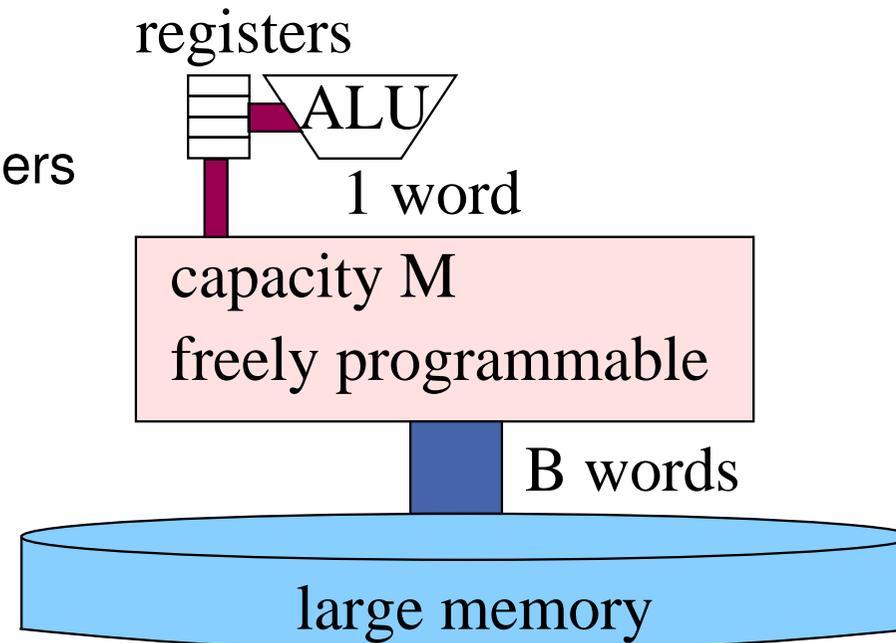
Aufgabe 2: effiziente Implementierung ohne überflüssiges Kopieren

## 7.3 Externes Sortieren

$n$ : Eingabegröße

$M$ : Größe des schnellen Speichers

$B$ : Blockgröße



**Procedure** externalMerge( $a, b, c$  :File of Element)

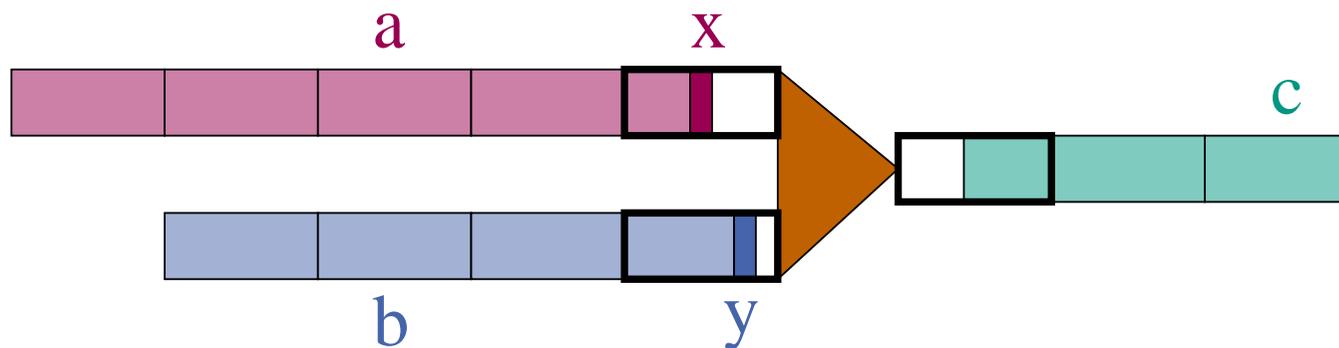
$x := a.readElement$  // Assume emptyFile.readElement =  $\infty$

$y := b.readElement$

**for**  $j := 1$  **to**  $|a| + |b|$  **do**

**if**  $x \leq y$  **then**  $c.writeElement(x)$ ;  $x := a.readElement$

**else**  $c.writeElement(y)$ ;  $y := b.readElement$



## Externes (binäres) Mischen – I/O-Analyse

Datei  $a$  lesen:  $\lceil |a|/B \rceil \leq |a|/B + 1$ .

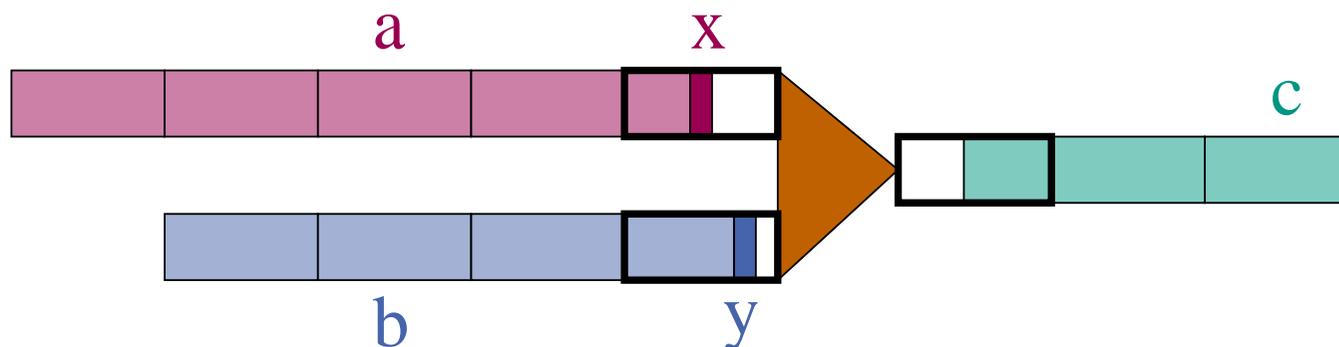
Datei  $b$  lesen:  $\lceil |b|/B \rceil \leq |b|/B + 1$ .

Datei  $c$  schreiben:  $\lceil (|a| + |b|)/B \rceil \leq (|a| + |b|)/B + 1$ .

Insgesamt:

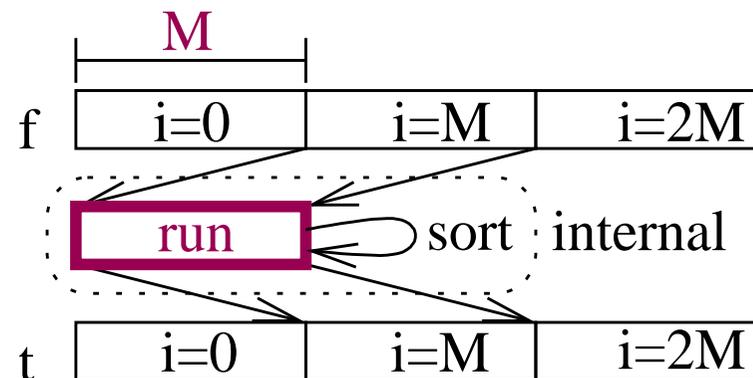
$$\leq 3 + 2 \frac{|a| + |b|}{B} \approx 2 \frac{|a| + |b|}{B}$$

Bedingung: Wir brauchen 3 Pufferblöcke, d.h.,  $M > 3B$ .



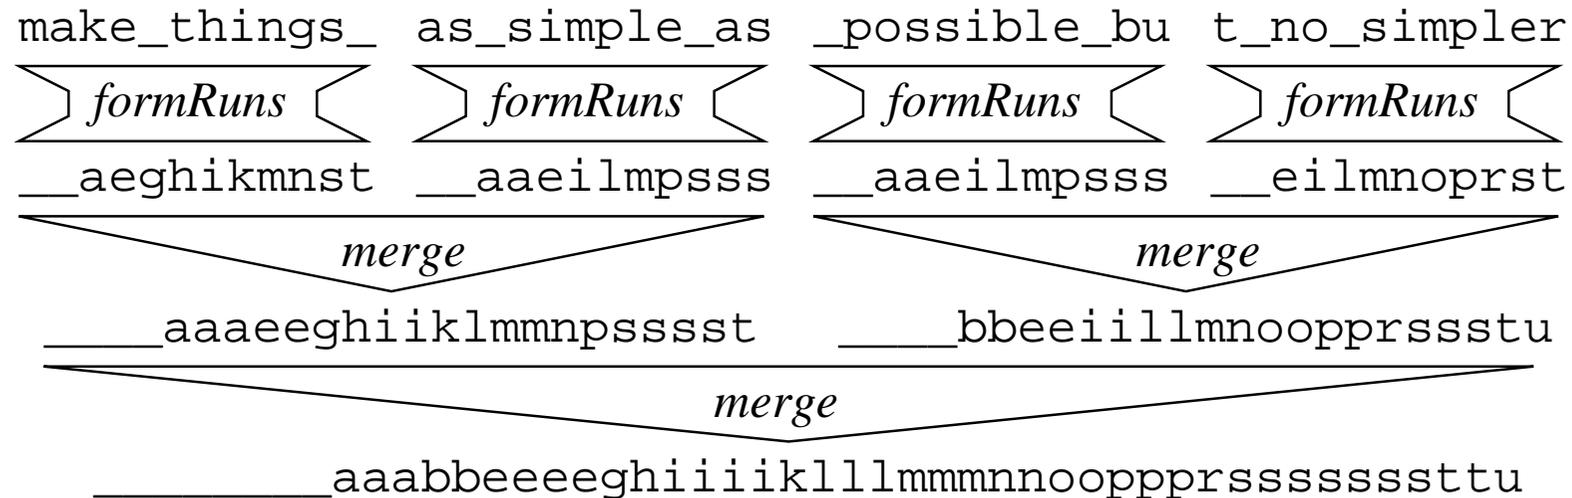
# Run Formation

Sortiere Eingabeportionen der Größe  $M$



$$\text{I/Os: } \approx 2 \frac{n}{B}$$

# Sortieren durch Externes Binäres Mischen



**Procedure** externalBinaryMergeSort // I/Os:  $\approx$

run formation //  $2n/B$

**while** more than one run left **do** //  $\lceil \log \frac{n}{M} \rceil \times$

    merge pairs of runs //  $2n/B$

output remaining run //  $\Sigma : 2 \frac{n}{B} \left( 1 + \lceil \log \frac{n}{M} \rceil \right)$

## Zahlenbeispiel: PC 2019

$$n = 2^{40} \text{ Byte}$$

$$M = 2^{34} \text{ Byte}$$

$$B = 2^{22} \text{ Byte}$$

I/O braucht  $2^{-4}$  s

$$\text{Zeit: } 2 \frac{n}{B} \left( 1 + \left\lceil \log \frac{n}{M} \right\rceil \right) = 2 \cdot 2^{17} \cdot (1 + 6) \cdot 2^{-4} \text{ s} = 2^{16} \text{ s} \approx 32 \text{ h}$$

Idee: 7 Durchläufe  $\rightsquigarrow$  2 Durchläufe

# Mehrwegemischen

**Procedure** multiwayMerge( $a_1, \dots, a_k, c$  :File of Element)

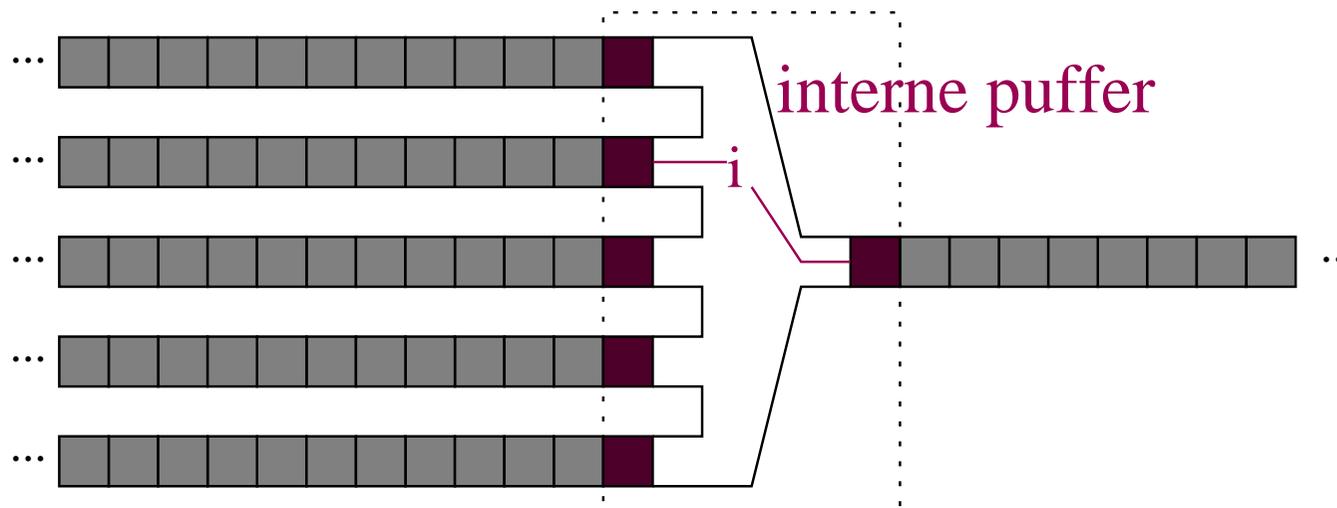
**for**  $i := 1$  **to**  $k$  **do**  $x_i := a_i$ .readElement

**for**  $j := 1$  **to**  $\sum_{i=1}^k |a_i|$  **do**

find  $i \in 1..k$  that minimizes  $x_i$  // no I/Os!,  $O(\log k)$  time

$c$ .writeElement( $x_i$ )

$x_i := a_i$ .readElement



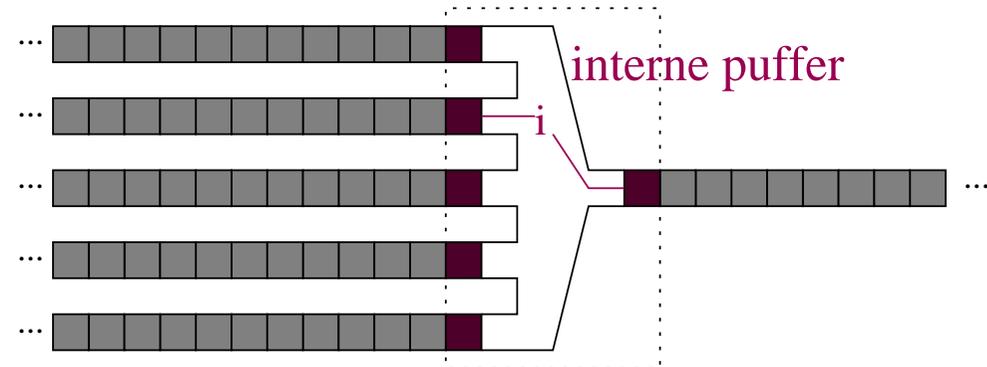
# Mehrwegemischen – Analyse

**I/Os:** Datei  $a_i$  lesen:  $\approx |a_i|/B$ .

Datei  $c$  schreiben:  $\approx \sum_{i=1}^k |a_i|/B$

Insgesamt:

$$\leq \approx 2 \frac{\sum_{i=1}^k |a_i|}{B}$$



Bedingung: Wir brauchen  $k + 1$  Pufferblöcke, d.h.,  $k + 1 < M/B$

(im Folgenden vereinfacht zu  $k < M/B$ )

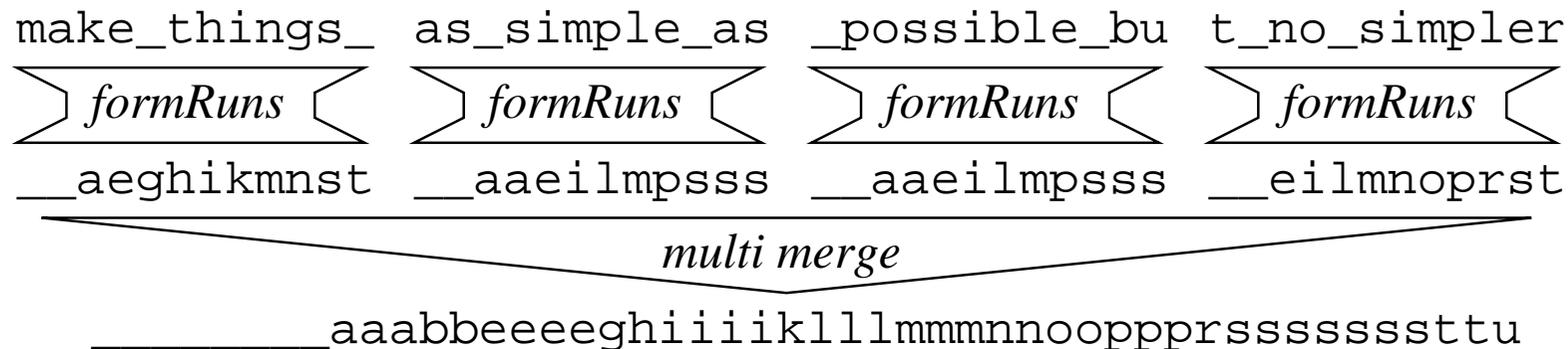
**Interne Arbeit:** (benutze Prioritätsliste !)

$$O\left(\log k \sum_{i=1}^k |a_i|\right)$$

# Sortieren durch Mehrwege-Mischen

- Sortiere  $\lceil n/M \rceil$  runs mit je  $M$  Elementen  $2n/B$  I/Os
- Mische jeweils  $M/B$  runs  $2n/B$  I/Os
- bis nur noch ein run übrig ist  $\times \left\lceil \log_{M/B} \frac{n}{M} \right\rceil$  Mischphasen

Insgesamt  $\text{sort}(n) := \frac{2n}{B} \left( 1 + \left\lceil \log_{M/B} \frac{n}{M} \right\rceil \right)$  I/Os



# Sortieren durch Mehrwege-Mischen

## Interne Arbeit:

$$O \left( \underbrace{n \log M}_{\text{run formation}} + \underbrace{n \log \frac{M}{B}}_{\text{PQ access per phase}} \overbrace{\left\lceil \log_{M/B} \frac{n}{M} \right\rceil}^{\text{phases}} \right) = O(n \log n)$$

## Mehr als eine Mischphase?:

Nicht für Hierarchie Hauptspeicher, Festplatte.

$$\text{Grund } \frac{\overbrace{M}^{>1000}}{B} > \frac{\overbrace{\text{RAM Euro/bit}}{\approx 150}}{\text{Platte Euro/bit}}$$

## Mehr zu externem Sortieren

Untere Schranke  $\approx \frac{2^{(?)n}}{B} \left( 1 + \left\lceil \log_{M/B} \frac{n}{M} \right\rceil \right)$  I/Os

[Aggarwal Vitter 1988]

Obere Schranke  $\approx \frac{2n}{DB} \left( 1 + \left\lceil \log_{M/B} \frac{n}{M} \right\rceil \right)$  I/Os (erwartet)

für  $D$  parallele Platten

[Hutchinson Sanders Vitter 2005, Dementiev Sanders 2003]

Offene Frage: deterministisch?

## Externe Prioritätslisten

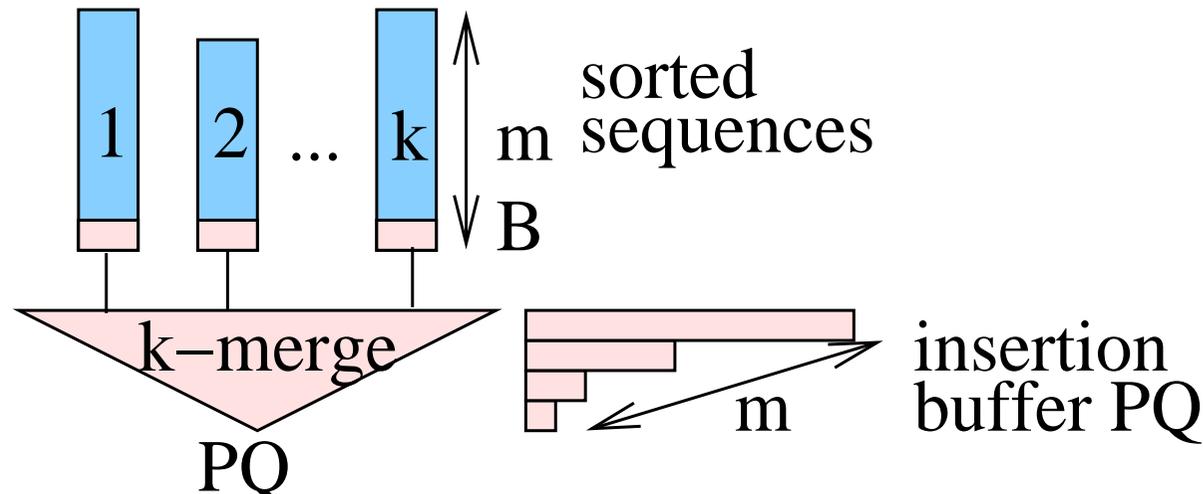
Problem: Binary heaps brauchen

$$\Theta\left(\log \frac{n}{M}\right) \text{ I/Os pro deleteMin}$$

Wir hätten gerne:

$$\Theta\left(\frac{1}{B} \log_{M/B} \frac{n}{M}\right) \text{ I/Os amortisiert}$$

# Mittelgroße PQs – $km \ll M^2 / B$ Einfügungen



Insert: Anfangs in **insertion buffer**.

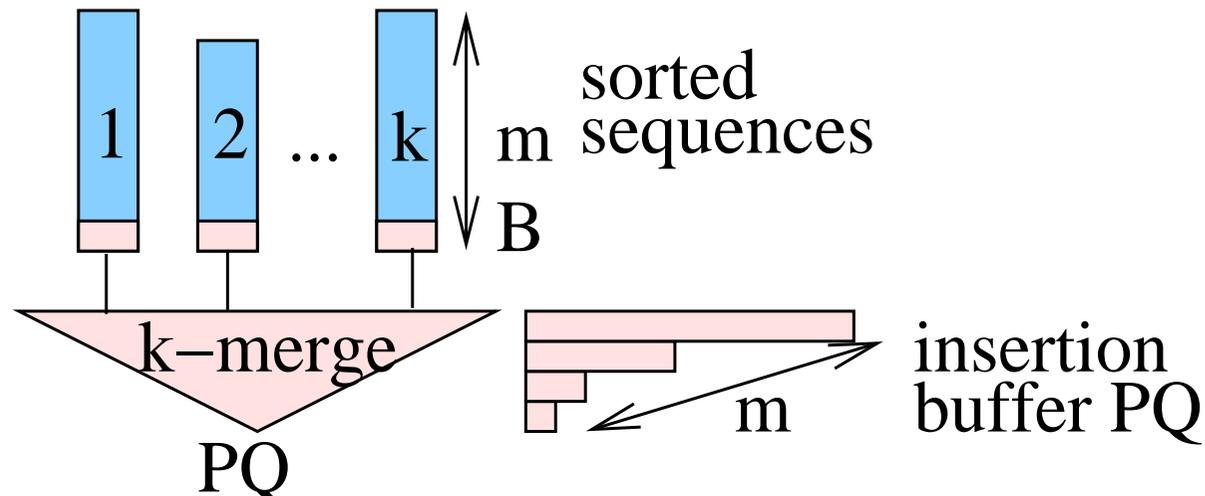
Überlauf  $\longrightarrow$

sort; flush; kleinster Schlüssel in merge-PQ

Delete-Min: deleteMin aus der PQ mit kleinerem min

## Analyse – I/Os

`deleteMin`: jedes Element wird  $\leq 1 \times$  gelesen, zusammen mit  $B$  anderen – **amortisiert**  $1/B$  penalty für **insert**.



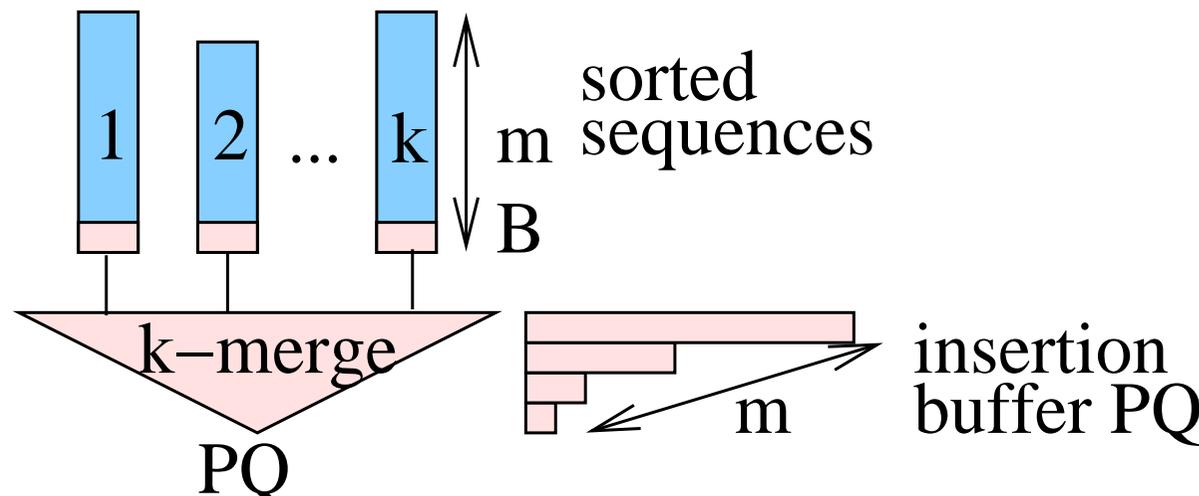
# Analyse – Vergleiche (Maß für interne Arbeit)

deleteMin:  $1 + O(\max(\log k, \log m)) = O(\log m)$

genauere Argumentation: amortisiert  $1 + \log k$  bei geeigneter PQ

insert:  $\approx m \log m$  alle  $m$  Ops. Amortisiert  $\log m$

Insgesamt nur  $\log km$  amortisiert !



# Große Queues

$$\approx \frac{2n}{B} \left( 1 + \left\lceil \log_{M/B} \frac{n}{M} \right\rceil \right)$$

I/Os für  $n$  Einfügeoperationen

$O(n \log n)$  Arbeit.

[Sanders 1999].

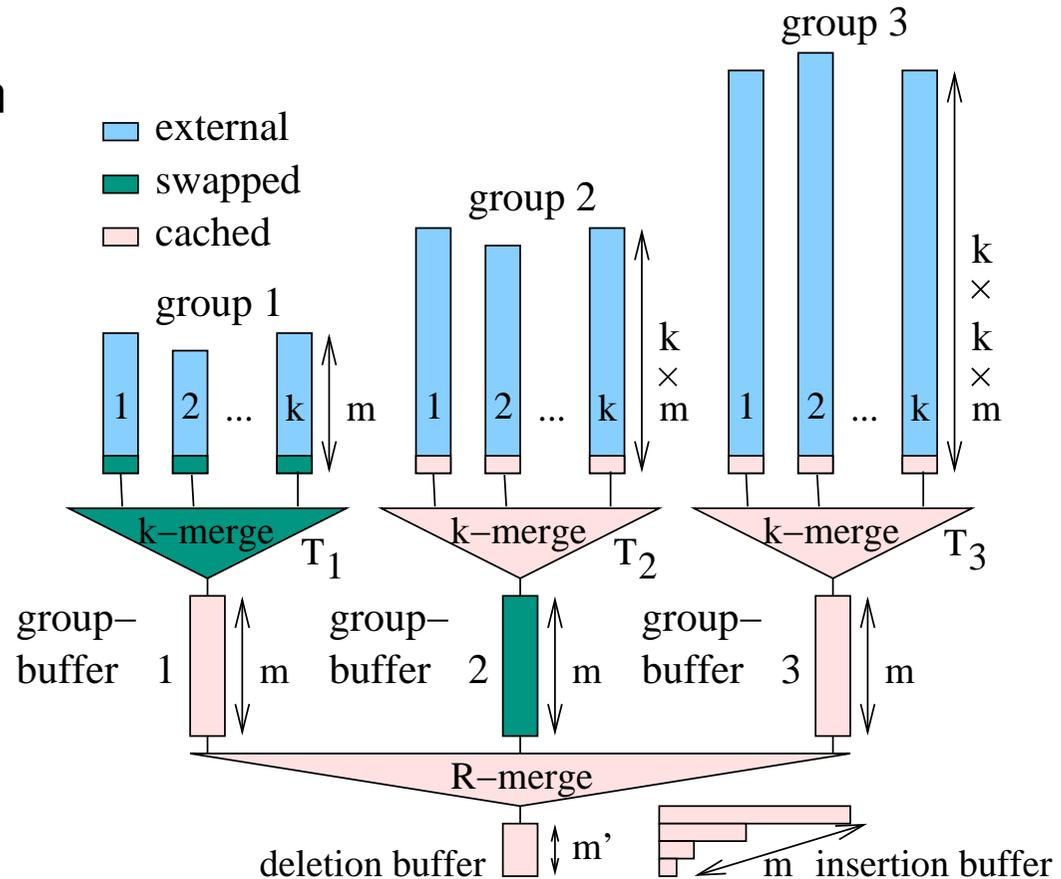
deleteMin:

“amortisiert umsonst”.

Details:

Vorlesung

Algorithm Engineering.



# Experiments

Keys: random 32 bit integers

Associated information: 32 dummy bits

Deletion buffer size: 32

Near optimal

Group buffer size: 256

: performance on

Merging degree  $k$ : 128

all machines tried!

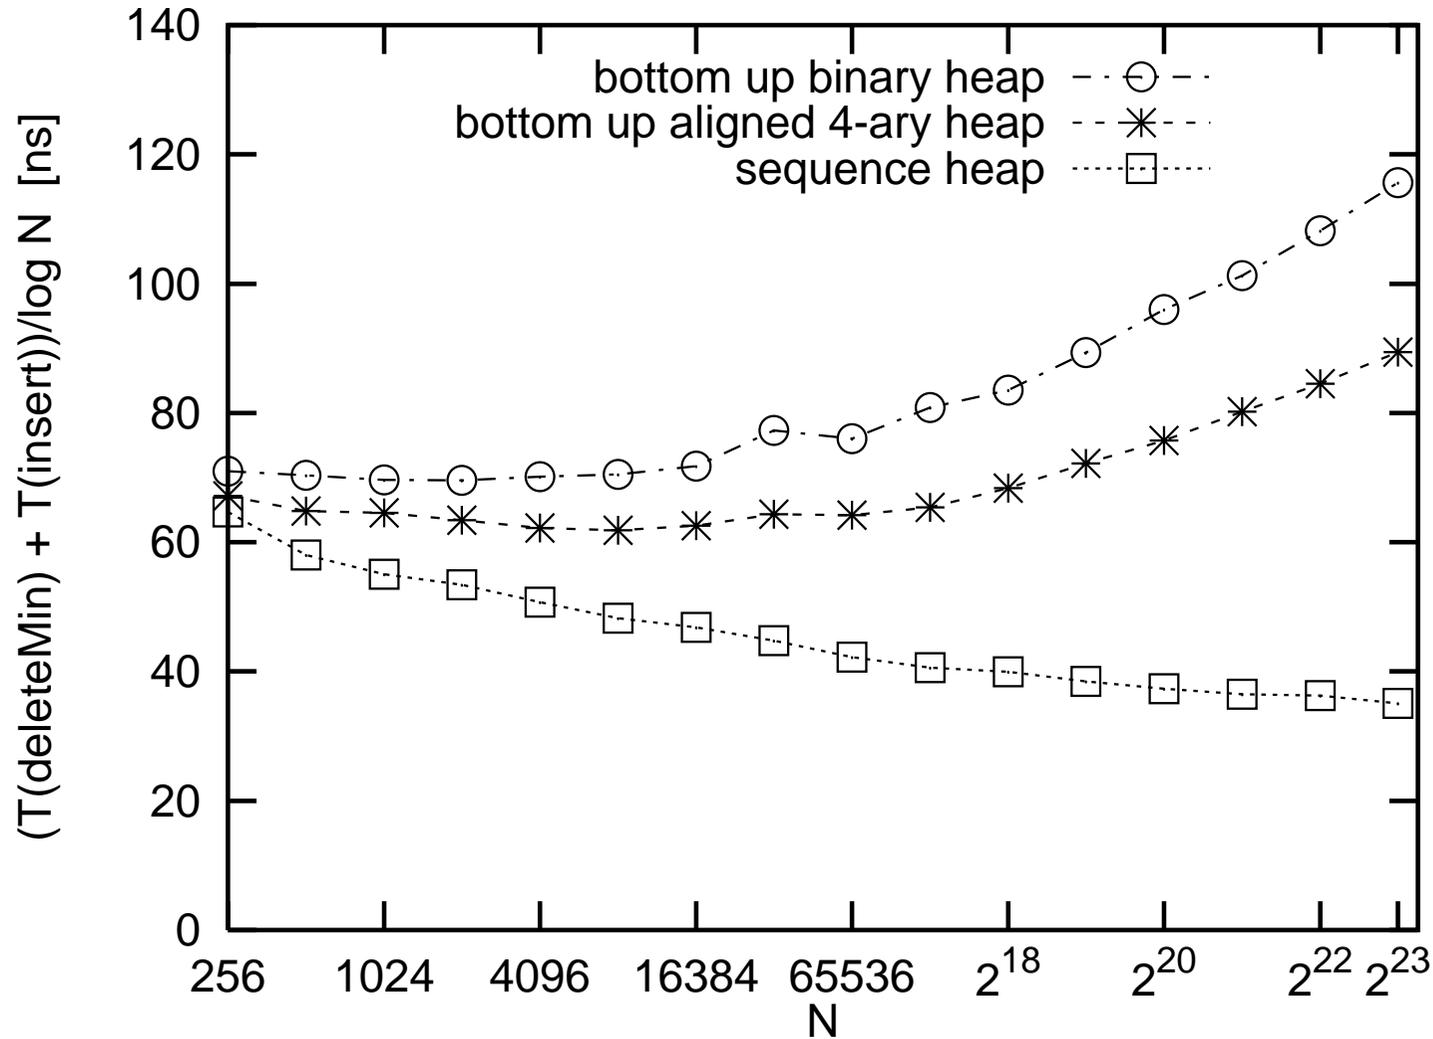
Compiler flags: Highly optimizing, nothing advanced

Operation Sequence:

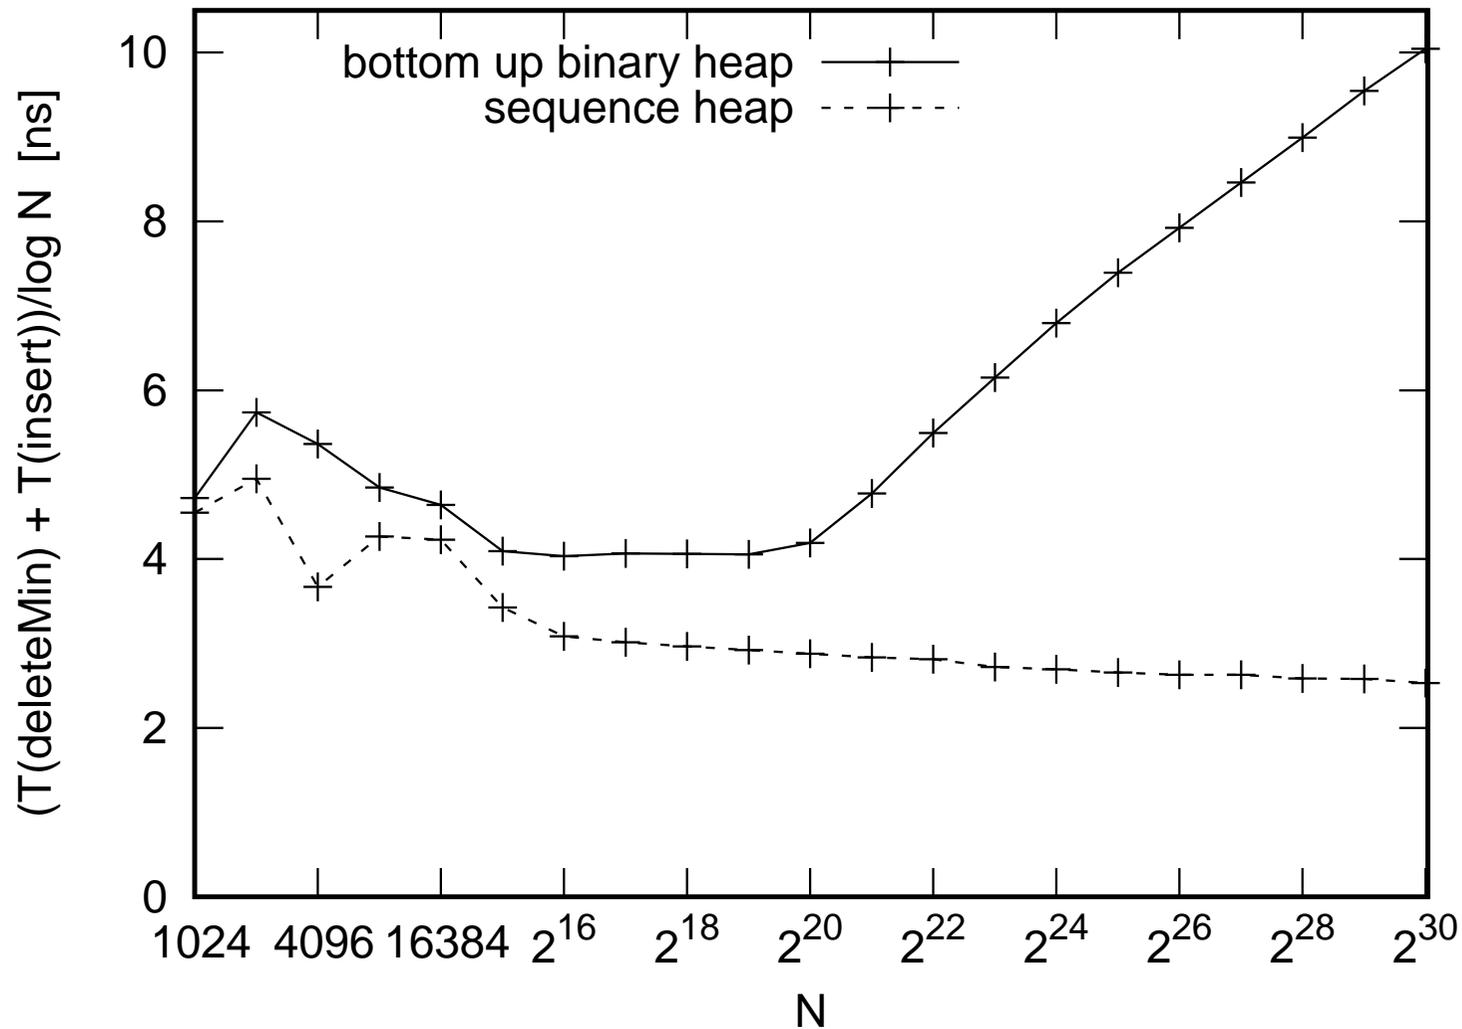
$(\text{Insert-DeleteMin-Insert})^N (\text{DeleteMin-Insert-DeleteMin})^N$

Near optimal performance on all machines tried!

# Alpha-21164, 533 MHz, 1997



# AMD Ryzen 1800X, 16MB L3, 3.6 GHz, 2017



## **Offenes Problem:**

Schnellere cache-effiziente PQs.

Mehrwegemischen  $\rightarrow$  Mehrwegeverteilen ?

Nochmal Faktor 2–3?

## **Bachelor/Masterarbeit:**

Idee umsetzen für **monotone** queues.

# Minimale Spannbäume

## Semiexterner Kruskal

Annahme:  $M = \Omega(n)$  konstant viele Maschinenworte pro Knoten

**Procedure** seKruskal( $G = (1..n, E)$ )

sort  $E$  by decreasing weight // sort( $m$ ) I/Os

Tc : UnionFind( $n$ )

**foreach**  $(u, v) \in E$  in ascending order of weight **do**

**if** Tc.find( $u$ )  $\neq$  Tc.find( $v$ ) **then**

        output  $\{u, v\}$

        Tc.union( $u, v$ ) // link reicht auch

## Externe MST-Berechnung

- Reduziere Knotenzahl mittels **Kontraktion** von MST-Kanten

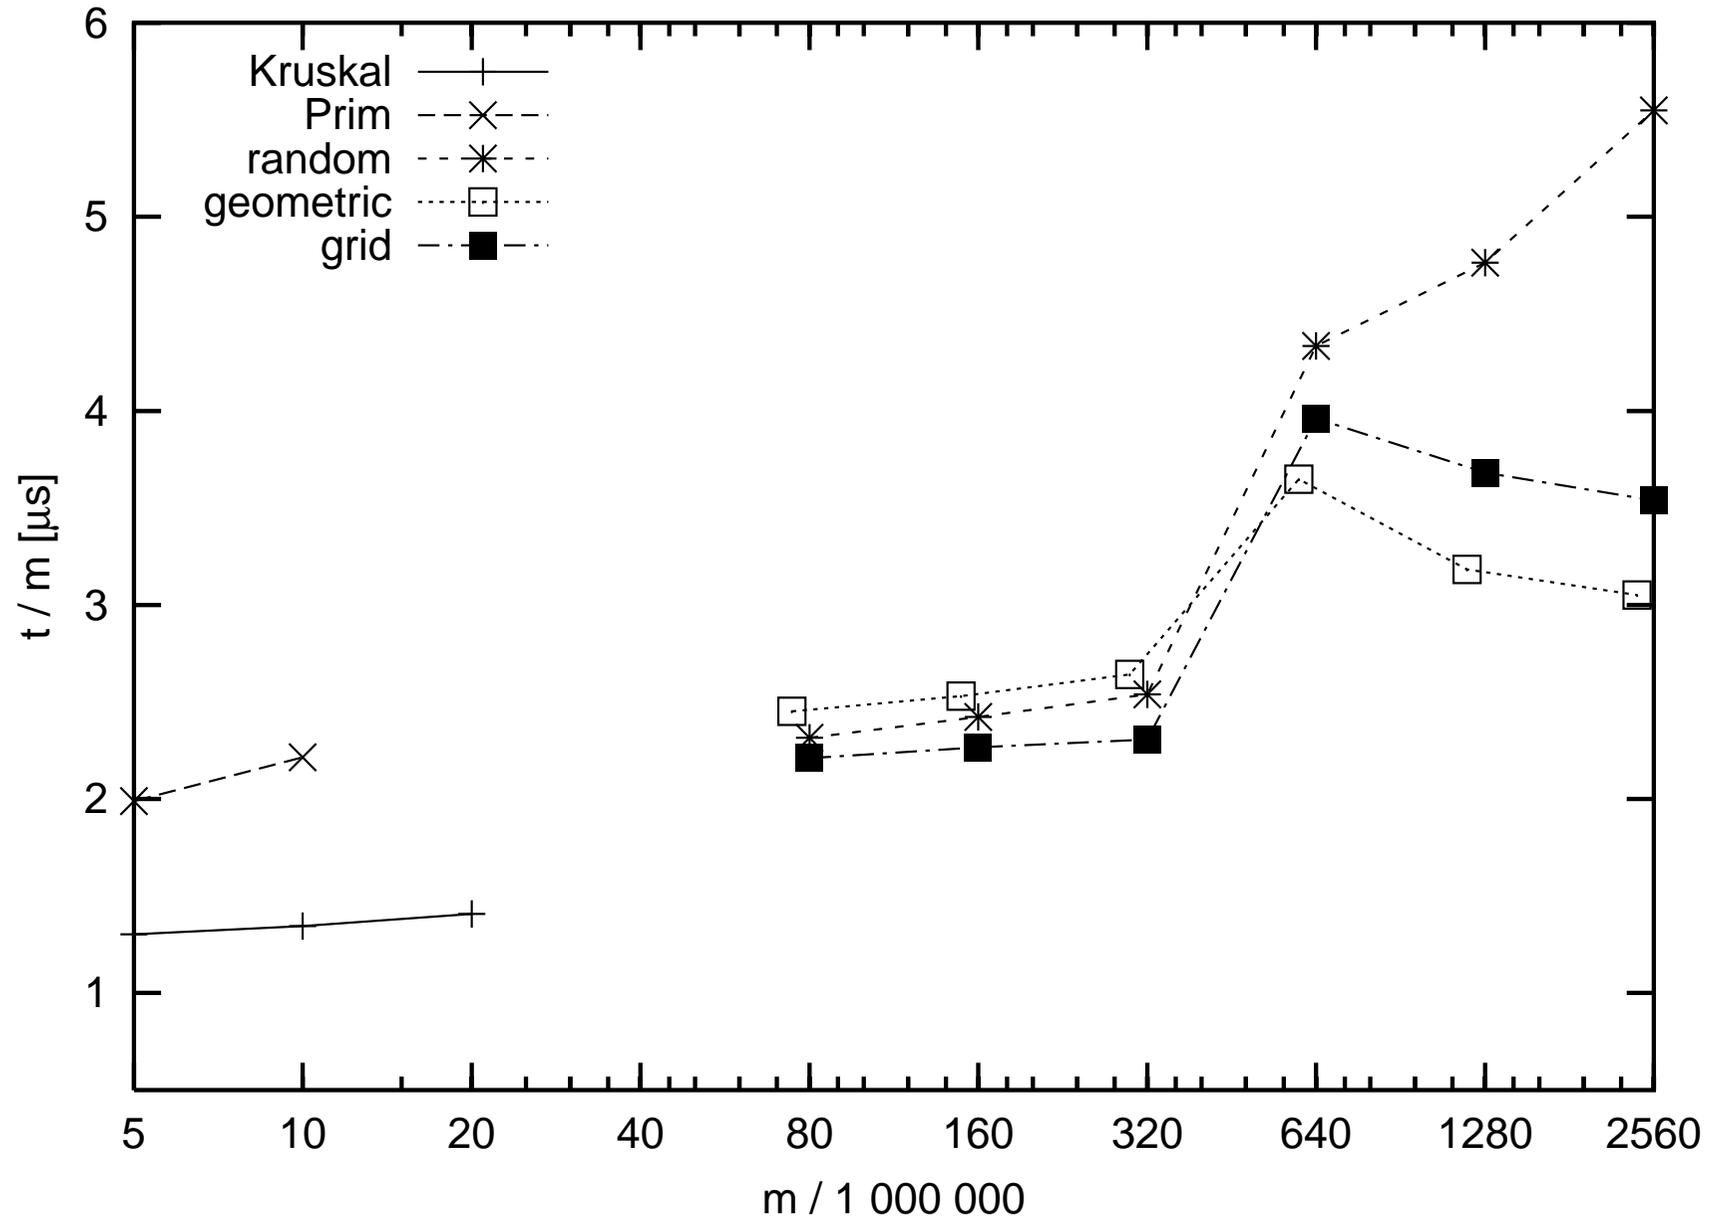
Details: Vorlesung Algorithm Engineering, Sibeyn's Algorithmus.

Implementierung  $\approx$  Sortierer + ext. Prioritätsliste + 1

Bildschirmseite. (STXXL Bibliothek)

- benutze semiexternen Algorithmus sobald  $n < M$ .

# Beispiel, Sibeyn's algorithm, $m \approx 2n$



# Mehr zu externen Algorithmen – Basic Toolbox ?

Externe Hashtabellen: geht aber 1 I/O pro Zugriff

Suchbäume:  $(a, 2a)$ -Bäume mit  $a = \Theta(B) \rightsquigarrow \log_B n$  I/Os für  
Basisoperationen. Brot-und-Butter-Datenstruktur für Datenbanken.  
Inzwischen auch in Dateisystemen. Viel Tuning: Große Blätter,  
Caching, ....

BFS: OK bei kleinem Graphdurchmesser

DFS: noch schwieriger. Heuristiken für den **semiexternen** Fall

kürzeste Wege: ähnlich BFS.

# 8 Approximationsalgorithmen

Eine Möglichkeit zum **Umgang mit NP-harten Problemen**

Beobachtung: Fast alle interessanten Optimierungsprobleme sind NP-hart

Auswege:

- Trotzdem optimale Lösungen suchen und riskieren, dass der Algorithmus nicht fertig wird
- Ad-hoc Heuristiken. Man kriegt eine Lösung aber wie gut ist die?
- Approximationsalgorithmen:**  
Polynomielle Ausführungszeit.  
Lösungen **garantiert „nah“** am Optimum.
- Problem umdefinieren/spezialisieren

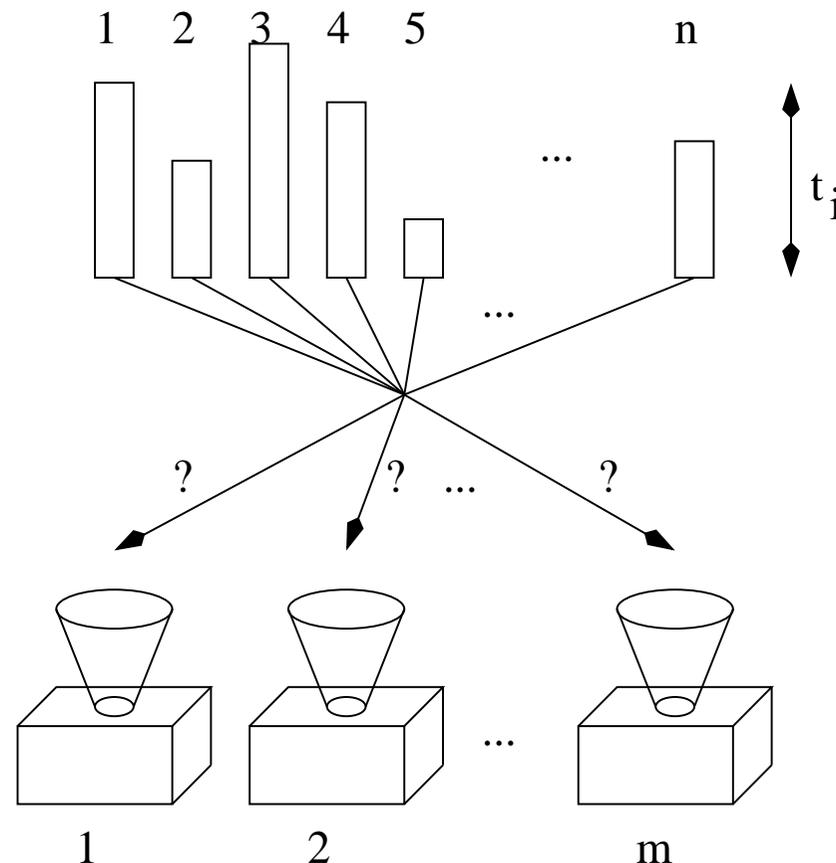
# Scheduling unabhängiger gewichteter Jobs auf parallelen Maschinen

$x(j)$ : Maschine auf der Job  $j$  ausgeführt wird

$L_i$ :  $\sum_{x(j)=i} t_j$ , Last von Maschine  $i$

Zielfunktion: Minimiere **Makespan**

$$L_{\max} = \max_i L_i$$



Details: Identische Maschinen, unabhängige Jobs, bekannte Ausführungszeiten, offline

## List Scheduling

ListScheduling( $n, m, \mathbf{t}$ )

$J := \{1, \dots, n\}$

array  $L[1..m] = [0, \dots, 0]$

**while**  $J \neq \emptyset$  **do**

    pick **any**  $j \in J$

$J := J \setminus \{j\}$

    // Shortest Queue:

    pick  $i$  such that  $L[i]$  is minimized

$\mathbf{x}(j) := i$

$L[i] := L[i] + t_j$

**return**  $\mathbf{x}$

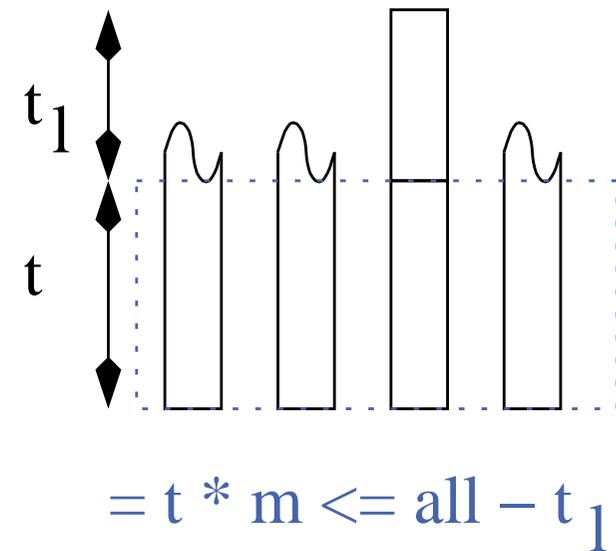
## Viele Kleine Jobs

**Lemma 1.** Falls  $\ell$  der zuletzt beendete Job ist, dann

$$L_{\max} \leq \sum_j \frac{t_j}{m} + \frac{m-1}{m} t_\ell$$

### Beweis

$$L_{\max} = t + t_\ell \leq \sum_{j \neq \ell} \frac{t_j}{m} + t_\ell = \sum_j \frac{t_j}{m} + \frac{m-1}{m} t_\ell$$



## Untere Schranken

**Lemma 2.**  $L_{\max} \geq \sum_j \frac{t_j}{m}$

**Lemma 3.**  $L_{\max} \geq \max_j t_j$

## Der Approximationsfaktor

Definition:

Ein Minimierungsalgorithmus erzielt **Approximationsfaktor**  $\rho$  bezüglich Zielfunktion  $f$  falls er für **alle** Eingaben  $I$ , eine Lösung  $\mathbf{x}(I)$  findet, so dass

$$\frac{f(\mathbf{x}(I))}{f(\mathbf{x}^*(I))} \leq \rho$$

wobei  $\mathbf{x}^*(I)$  die optimale Lösung für Eingabe  $I$  bezeichnet.

**Satz:** ListScheduling erzielt Approximationsfaktor  $2 - \frac{1}{m}$ .

**Beweis:**

$$\frac{f(\mathbf{x})}{f(\mathbf{x}^*)} \quad \text{(obere Schranke Lemma 1)}$$

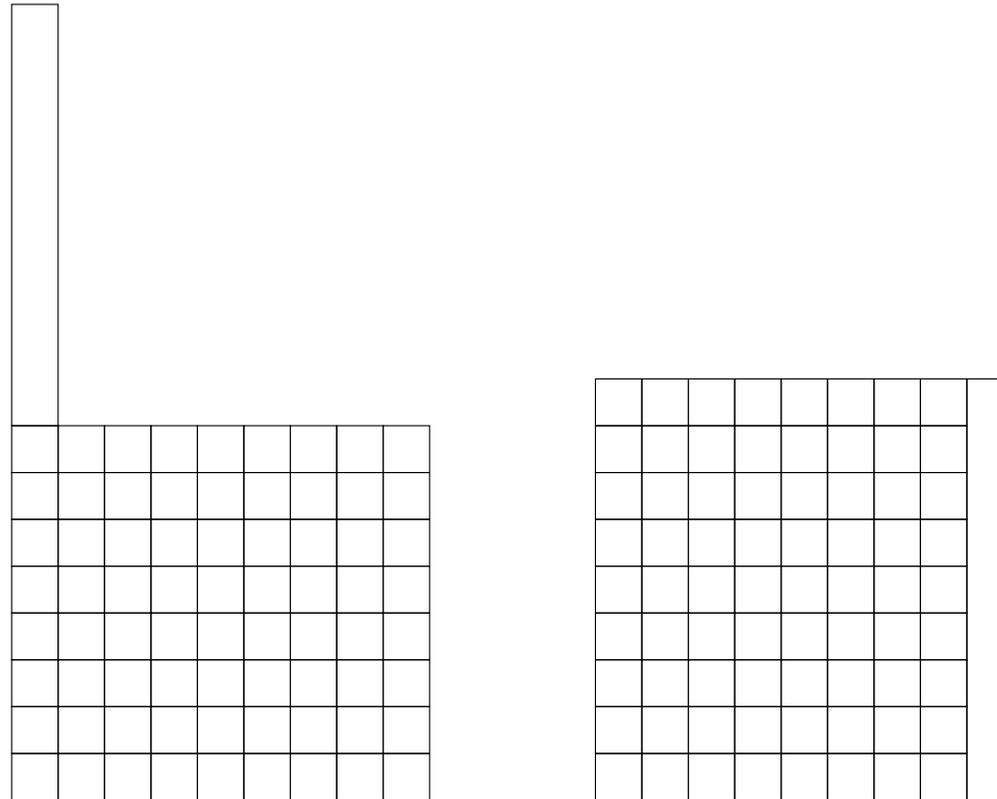
$$\leq \frac{\sum_j t_j / m}{f(\mathbf{x}^*)} + \frac{m-1}{m} \cdot \frac{t_\ell}{f(\mathbf{x}^*)} \quad \text{(untere Schranke Lemma 2)}$$

$$\leq 1 + \frac{m-1}{m} \cdot \frac{t_\ell}{f(\mathbf{x}^*)} \quad \text{(untere Schranke Lemma 3)}$$

$$\leq 1 + \frac{m-1}{m} = 2 - \frac{1}{m}$$

## Diese Schranke ist bestmöglich

Eingabe:  $m(m - 1)$  Jobs der Größe 1 und ein Job der Größe  $m$ .



List Scheduling:  $2m-1$

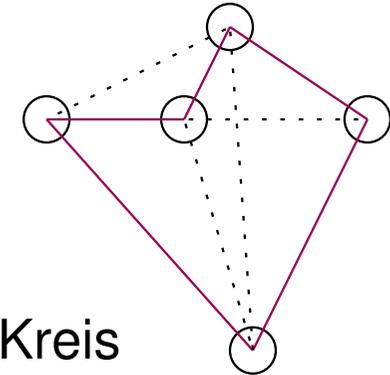
OPT:  $m$

Also ist der Approximationsfaktor  $\geq 2 - 1/m$ .

## Mehr zu Scheduling (siehe Approx-Vorlesung)

- 4/3-Approximation: Sortiere die Jobs nach **absteigender Größe**.  
Dann List-Scheduling. Zeit  $O(n \log n)$ .
- Schnelle 7/6 Approximation: Rate Makespan (binäre Suche).  
Dann **Best Fit Decreasing**.
- PTAS** ... später ...
- Uniform machines: Maschine  $i$  hat **Geschwindigkeit  $v_i$**  job  $j$   
braucht Zeit  $t_j/v_i$  auf Maschine  $j$ .  $\rightsquigarrow$  relative einfache  
Verallgemeinerung
- Unrelated Machines** Job  $j$  braucht Zeit  $t_{ji}$  auf Maschine  $j$ .  
2-Approximation. Ganz anderer Algorithmus.
- uvam: Andere Zielfunktionen, Reihenfolgebeschränkungen, ...

# Nichtapproximierbarkeit des Handlungsreisendenproblems (TSP)



Gegeben ein Graph  $G = (V, V \times V)$ , finde einen einfachen Kreis  $C = (v_1, v_2, \dots, v_n, v_1)$  so dass  $n = |V|$  und  $\sum_{(u,v) \in C} d(u, v)$  minimiert wird.

**Satz:** Es ist NP-hart das TSP innerhalb irgendeines Faktors  $a$  zu approximieren.

**Beweisansatz:** Es genügt zu zeigen, dass  $\text{HamiltonCycle} \leq_p a\text{-Approximation von TSP}$

## $\alpha$ -Approximation von TSP

### Gegeben:

Graph  $G = (V, V \times V)$  mit Kantengewichten  $d(u, v)$ ,  
Parameter  $W$ .

Gesucht ist ein Algorithmus, mit folgenden Eigenschaften:

$[G, W]$  wird akzeptiert  $\longrightarrow \exists$  Tour mit Gewicht  $\leq \alpha W$ .

$[G, W]$  wird abgelehnt  $\longrightarrow \nexists$  Tour mit Gewicht  $\leq W$ .

## HamiltonCycle $\leq_p$ $a$ -Approximation von TSP

Sei  $G = (V, E)$  beliebiger ungerichteter Graph.

Definiere  $d(u, v) = \begin{cases} 1 & \text{falls } (u, v) \in E \\ 1 + an & \text{sonst} \end{cases}$

Dann und nur dann, wenn  $G$  einen Hamiltonkreis hat gilt

$\exists$  TSP Tour mit **Kosten  $n$**

(sonst optimale **Kosten  $\geq (n - 1) \cdot 1 + (an + 1) = an + n > an$** )

Entscheidungsalgorithmus für Hamiltonkreis:

Führe  $a$ -approx TSP auf  $[G, n]$  aus.

Wird akzeptiert

$\longrightarrow \exists$  Tour mit Gewicht  $\leq an$

$\longrightarrow \exists$  Tour mit Gewicht  $n \longrightarrow \exists$  Hamiltonpfad

sonst  $\nexists$  Hamiltonpfad

## TSP mit Dreiecksungleichung

$G$  (ungerichtet) erfüllt die Dreiecksungleichung

$$\forall u, v, w \in V : d(u, w) \leq d(u, v) + d(v, w)$$

## Metrische Vervollständigung

Betrachte beliebigen unger. Graph  $G = (V, E)$  mit Gewichtsfunktion

$c : E \rightarrow \mathbb{R}_+$ . Definiere

$d(u, v) :=$  Länge des kürzesten Pfades von  $u$  nach  $v$

Beispiel: (ungerichteter) Strassengraph  $\longrightarrow$  Abstandstabelle

## Euler-Touren/-Kreise

Betrachte beliebigen zusammenhängenden ungerichteten (Multi-)Graph  $G = (V, E)$  mit  $|E| = m$ .

Ein Pfad  $P = \langle e_1, \dots, e_m \rangle$  ist ein **Euler-Kreis** falls  $\{e_1, \dots, e_m\} = E$ .  
(Jede **Kante** wird genau einmal besucht)

Satz:  $G$  hat Euler-Kreis gdw.  $G$  ist zusammenhängend und  $\forall v \in V : \text{Grad}(v)$  ist gerade.

Euler-Kreise lassen sich in Zeit  $O(|E| + |V|)$  finden.

## 2-Approximation durch minimalen Spannbaum

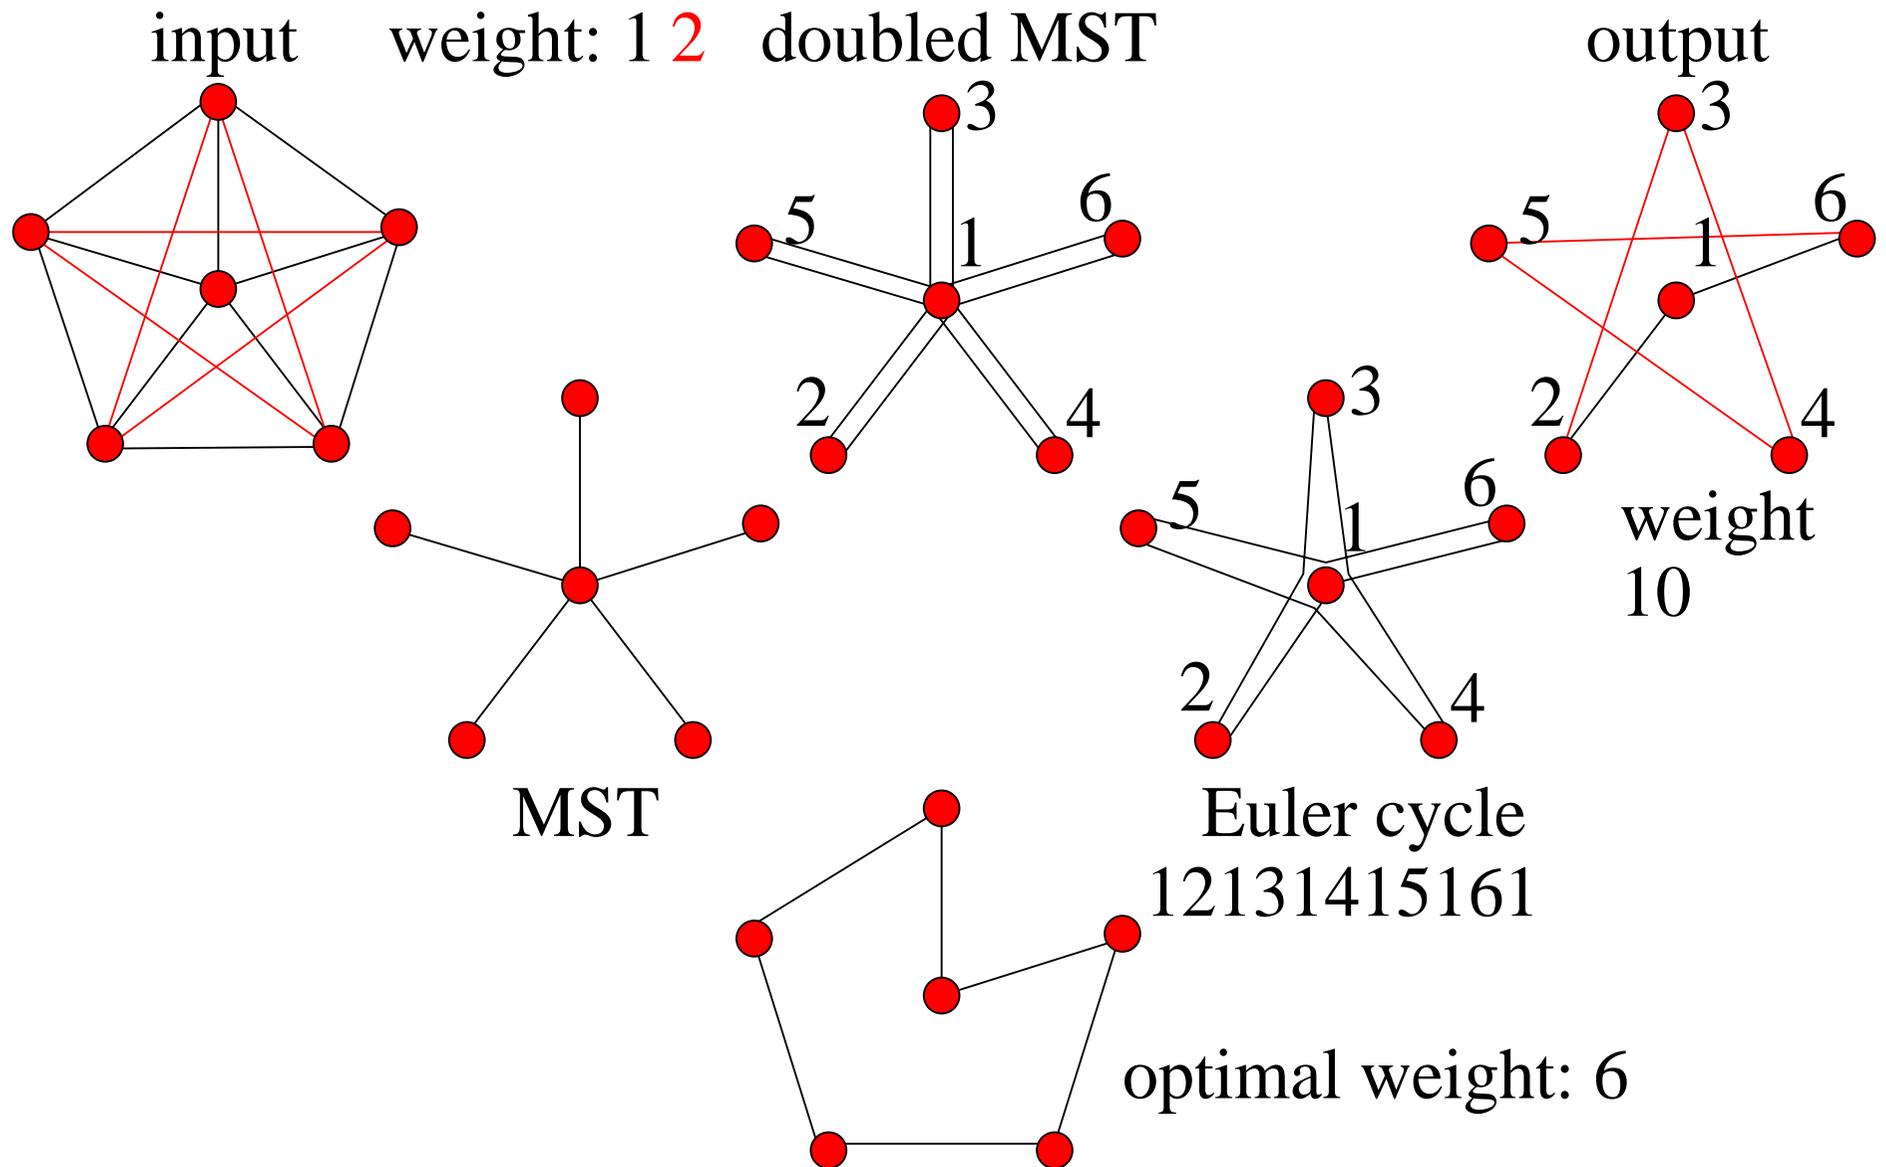
### Lemma 4.

Gesamtgewicht eines *MST*  $\leq$   
Gesamtgewicht jeder *TSP-Tour*

Algorithmus:

$T := \text{MST}(G)$	// $\text{weight}(T) \leq \text{opt}$
$T' := T$ with every edge doubled	// $\text{weight}(T') \leq 2\text{opt}$
$T'' := \text{EulerKreis}(T')$	// $\text{weight}(T'') \leq 2\text{opt}$
output $\text{removeDuplicates}(T'')$	// <b>shortcutting</b>

# Beispiel



## Beweis von $\text{Gewicht MST} \leq \text{Gewicht TSP-Tour}$

Sei  $T$  die optimale TSP tour

entferne eine Kante

macht  $T$  leichter

nun ist  $T$  ein Spannbaum

der nicht leichter sein kann als der

MST



### Allgemeine Technik: Relaxation

hier: ein TSP-Pfad ist ein Spezialfall eines Spannbaums

## Mehr TSP

- Praktisch bessere 2-Approximationen, z.B. lightest edge first
- Relativ einfache aber unpraktische 3/2-Approximation  
(MST + min. weight perfect matching + Euler-Kreis)
- PTAS for **Euclidean TSP**
- Versuchskanichen für praktisch jede Optimierungs**heuristik**
- Optimale Lösungen für praktische Eingaben. Faustregel:  
**Falls es in den Speicher passt, läßt sichs lösen.**  
[\[http://www.tsp.gatech.edu/concorde.html\]](http://www.tsp.gatech.edu/concorde.html)  
sechsstellige Anzahl Codezeilen.
- TSP-artige Anwendungen sind meist komplizierter

# Pseudopolynomielle Algorithmen

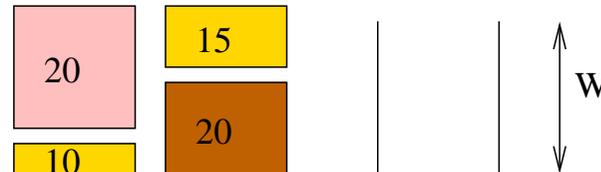
$\mathcal{A}$  ist **pseudopolynomieller** Algorithmus falls

$$\text{Time}_{\mathcal{A}}(n) \in \mathbf{P}(n)$$

wobei  $n$  die Anzahl Eingabebits ist,

wenn alle Zahlen **unär** codiert werden ( $k \equiv 1^k$ ).

## Beispiel Rucksackproblem



- $n$  Gegenstände mit Gewicht  $w_i \in \mathbb{N}$  und profit  $p_i$   
oBdA:  $\forall i \in 1..n : w_i \leq W$
- Wähle eine Teilmenge  $\mathbf{x}$  von Gegenständen
- so dass  $\sum_{i \in \mathbf{x}} w_i \leq W$  und
- maximiere den Profit  $\sum_{i \in \mathbf{x}} p_i$

# Dynamische Programmierung **nach Profit**

$C(i, P)$  := kleinste Kapazität für Gegenstände  $1, \dots, i$  die Profit  $\geq P$  ergeben.

## Lemma 5.

$$\forall 1 \leq i \leq n : C(i, P) = \min(C(i-1, P), \\ C(i-1, P - p_i) + w_i)$$

# Dynamische Programmierung **nach Profit**

Sei  $\hat{P}$  obere Schranke für den Profit (z.B.  $\sum_i p_i$ ).

Zeit:  $O(n\hat{P})$  **pseudo**-polynomiell

z.B.  $0..n \times 0..\hat{P}$  Tabelle  $C(i, P)$  spaltenweise ausfüllen

Platz:  $\hat{P} + O(n)$  Maschinenworte plus  $\hat{P}n$  bits.

# Fully Polynomial Time Approximation Scheme

Algorithm  $\mathcal{A}$  ist ein

(Fully) Polynomial Time Approximation Scheme

für  $\begin{matrix} \text{minimization} \\ \text{maximization} \end{matrix}$  Problem  $\Pi$  falls:

Eingabe: Instanz  $I$ , Fehlerparameter  $\varepsilon$

Ausgabequalität:  $f(\mathbf{x}) \begin{matrix} \leq \\ \geq \end{matrix} \begin{pmatrix} 1+\varepsilon \\ 1-\varepsilon \end{pmatrix} \text{opt}$

Zeit: Polynomiell in  $|I|$  (und  $1/\varepsilon$ )

# Beispielschranken

PTAS	FPTAS
$n + 2^{1/\varepsilon}$	$n^2 + \frac{1}{\varepsilon}$
$n^{\log \frac{1}{\varepsilon}}$	$n + \frac{1}{\varepsilon^4}$
$n^{\frac{1}{\varepsilon}}$	$n/\varepsilon$
$n^{42/\varepsilon^3}$	$\vdots$
$n + 2^{2^{1000/\varepsilon}}$	$\vdots$
$\vdots$	$\vdots$

## FPTAS für Knapsack

$$P := \max_i p_i$$

// maximaler Einzelprofit

$$K := \frac{\varepsilon P}{n}$$

// Skalierungsfaktor

$$p'_i := \left\lfloor \frac{p_i}{K} \right\rfloor$$

// skaliere Profite

$$\mathbf{x}' := \text{dynamicProgrammingByProfit}(\mathbf{p}', \mathbf{w}, C)$$

gib  $\mathbf{x}'$  aus

**Lemma 6.**  $\mathbf{p} \cdot \mathbf{x}' \geq (1 - \varepsilon)\text{opt}$ .

*Beweis.* Betrachte die optimale Lösung  $\mathbf{x}^*$ .

$$\begin{aligned} \mathbf{p} \cdot \mathbf{x}^* - K\mathbf{p}' \cdot \mathbf{x}^* &= \sum_{i \in \mathbf{x}^*} \left( p_i - K \left\lfloor \frac{p_i}{K} \right\rfloor \right) \\ &\leq \sum_{i \in \mathbf{x}^*} \left( p_i - K \left( \frac{p_i}{K} - 1 \right) \right) = |\mathbf{x}^*|K \leq nK, \end{aligned}$$

also,  $K\mathbf{p}' \cdot \mathbf{x}^* \geq \mathbf{p} \cdot \mathbf{x}^* - nK$ . Weiterhin,

$$K\mathbf{p}' \cdot \mathbf{x}^* \leq K\mathbf{p}' \cdot \mathbf{x}' = \sum_{i \in \mathbf{x}'} K \left\lfloor \frac{p_i}{K} \right\rfloor \leq \sum_{i \in \mathbf{x}'} K \frac{p_i}{K} = \mathbf{p} \cdot \mathbf{x}'. \text{ Also,}$$

$$\mathbf{p} \cdot \mathbf{x}' \geq K\mathbf{p}' \cdot \mathbf{x}^* \geq \mathbf{p} \cdot \mathbf{x}^* - nK = \text{opt} - \varepsilon \underbrace{P}_{\leq \text{opt}} \geq (1 - \varepsilon)\text{opt}$$

□

**Lemma 7.** Laufzeit  $O(n^3 / \varepsilon)$ .

*Beweis.* Die Laufzeit  $O(n\hat{P}')$  der dynamischen Programmierung dominiert:

$$n\hat{P}' \leq n \cdot (n \cdot \max_{i=1}^n p'_i) = n^2 \left[ \frac{P}{K} \right] = n^2 \left[ \frac{Pn}{\varepsilon P} \right] \leq \frac{n^3}{\varepsilon}.$$

□

# Das beste bekannte FPTAS

[Kellerer, Pferschy 04]

$$O\left(\min\left\{n \log \frac{1}{\varepsilon} + \frac{\log^2 \frac{1}{\varepsilon}}{\varepsilon^3}, \dots\right\}\right)$$

- Weniger buckets  $C_j$  (nichtuniform)
- Ausgefeilte dynamische Programmierung

# Optimale Algorithmen für das Rucksackproblem

Annähernd Linearzeit für fast alle Eingaben! In Theorie und Praxis.

[Beier, Vöcking, An Experimental Study of Random Knapsack Problems, European Symposium on Algorithms, 2004.]

[Kellerer, Pferschy, Pisinger, Knapsack Problems, Springer 2004.]

# 9 Fixed-Parameter-Algorithmen

Praktische Beobachtung: Auch bei NP-harten Problemen können wir u.U. exakte Lösungen finden:  
... für **einfache** Instanzen.

Wie charakterisiert man Einfachheit ?

Durch einen weiteren Parameter  $k$  (neben der Eingabegröße)

Beispiel:  $k = \text{Ausgabegröße}$

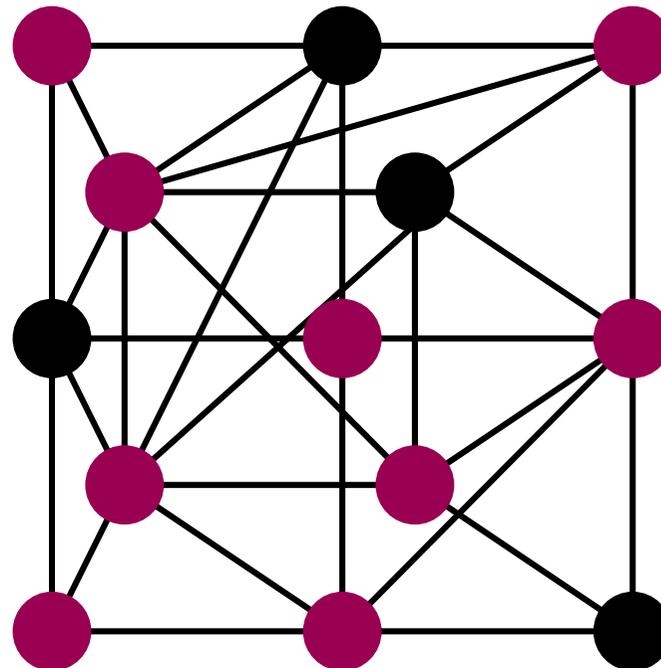
[Niedermeier, Invitation to Fixed Parameter Algorithms, Oxford U. Press, 2006]

# Beispiel: VERTEX COVER (Knotenüberdeckung)

**Gegeben:** ungerichteter Graph  $G = (V, E)$ ,

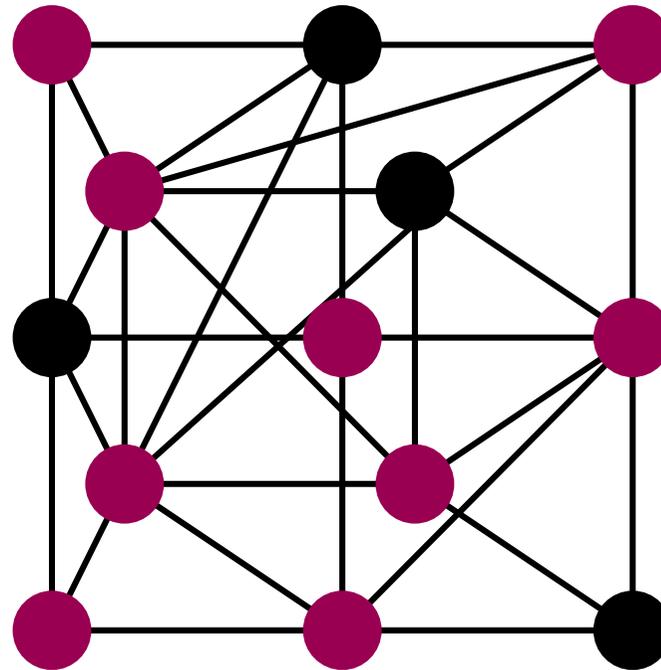
Parameter  $k \in \mathbb{N}$ .

**Frage:**  $\exists V' \subseteq V : |V'| = k \wedge \forall \{u, v\} \in E : u \in V' \vee v \in V'$



# VERTEX COVER Grundlegendes

- Eines der (21) klassischen **NP-harten** Probleme
- Trivialer  $O(n^{k+1})$  Brute-Force-Algorithmus
- Äquivalent zu max. independent set (Komplement)



# Fixed parameter tractable

Eine formale Sprache  $L \in \text{FPT}$  bzgl. Parameter  $k \Leftrightarrow$

$\exists$  Algorithmus mit Laufzeit  $\mathcal{O}(f(k) \cdot p(n))$ ,

$f$  berechenbare Funktion, nicht von  $n$  abhängig,

$p$  Polynom, nicht von  $k$  abhängig.

**Beispiele:**  $2^k n^2$ ,  $k^{k!} n^{333}$ ,  $n + 1.1^k$

**Gegenbeispiele:**  $n^k$ ,  $n^{\log \log k}$

## **Beispiel: VERTEX COVER**

**Satz:** Vertex Cover ist in FPT bzgl. des Parameters  
Ausgabekomplexität

Wir entwickeln Algorithmen mittels zweier auch praktisch wichtiger  
Entwurfstechniken:

1. **Kernbildung:** (Kernelization) Reduktionsregeln reduzieren Problem  
auf Größe  $O(f(k))$
2. Systematische **Suche** mit **beschränkter Tiefe**.

## Naive tiefenbeschränkte Suche

**Function**  $\text{vertexCover}(G = (V, E), k) : \text{Boolean}$

**if**  $|E| = 0$  **then return** true

**if**  $k = 0$  **then return** false

pick any edge  $\{u, v\} \in E$

**return**  $\text{vertexCover}(G - v, k - 1) \vee$   
 $\text{vertexCover}(G - u, k - 1)$

Operation  $G - v$  removes node  $v$  and its incident edges

## Naive tiefenbeschränkte Suche – Korrektheit

```
Function vertexCover( $G = (V, E), k$ ) : Boolean
  if  $|E| = 0$  then return true           // triviales Problem
  if  $k = 0$  then return false           // unmögliches Problem
  pick any edge  $\{u, v\} \in E$  //  $u$  oder  $v$  müssen im cover sein !
  //Fallunterscheidung:
  return vertexCover( $G - v, k - 1$ )  $\vee$  // Fall  $v$  in cover
         vertexCover( $G - u, k - 1$ ) // Fall  $u$  in cover
```

## Naive tiefenbeschränkte Suche – Laufzeit

```

Function vertexCover( $G = (V, E), k$ ) : Boolean
    if  $|E| = 0$  then return true //  $O(1)$ 
    if  $k = 0$  then return false //  $O(1)$ 
    pick any edge  $\{u, v\} \in E$  //  $O(1)$ 
    return vertexCover( $G - v, k - 1$ )  $\vee$  //  $O(n + m) + T(k - 1)$ 
        vertexCover( $G - u, k - 1$ ) //  $T(k - 1)$ 
    
```

Rekursionstiefe  $k \rightsquigarrow O(2^k)$  rekursive Aufrufe also

Laufzeit  $O(2^k(n + m))$ .

**Formaler:** Lösung der **Rekurrenz**  $T(k) = (n + m) + 2T(k - 1)$

## Kernbildung für Vertex Cover

Beobachtung:  $\forall v \in V : \text{degree}(v) > k \implies v \in \text{Lösung} \vee \text{unlösbar}$

**Function** kernelVertexCover( $G = (V, E), k$ ) : Boolean

**if**  $|E| = 0$  **then return** true

**while**  $\exists v \in V : \text{degree}(v) > k$  **do**

**if**  $k = 0$  **then return** false

$G := G - v$

$k := k - 1$

remove isolated nodes

**if**  $|E| > k^2$  **then return** false

**return** vertexCover( $G, k$ )

## Kernbildung für Vertex Cover – Korrektheit

Beobachtung:  $\forall v \in V : \text{degree}(v) > k \implies v \in \text{Lösung} \vee \text{unlösbar}$

**Function** kernelVertexCover( $G = (V, E), k$ ) : Boolean

**if**  $|E| = 0$  **then return** true

**while**  $\exists v \in V : \text{degree}(v) > k$  **do** // siehe Beobachtung

**if**  $k = 0$  **then return** false //  $m > k = 0!$

$G := G - v$  //  $v$  muss in die Lösung!

$k := k - 1$

remove isolated nodes // nutzlose Knoten

**if**  $|E| > k^2$  **then return** false //  $\leq k$  nodes  $\times \leq k$  neighbors

**return** vertexCover( $G, k$ )

## Kernbildung für Vertex Cover – Laufzeit

```

Function kernelVertexCover( $G = (V, E), k$ ) : Boolean
  if  $|E| = 0$  then return true
  while  $\exists v \in V : \text{degree}(v) > k$  do                                //  $\leq k \times$ 
    if  $k = 0$  then return false                                       //  $m \geq k > 0 !$ 
     $G := G - v$  //  $v$  muss in die Lösung!                               //  $O(n + m)$ 
     $k := k - 1$ 
  remove isolated nodes                                                // nutzlose Knoten
  //Insgesamt  $O((n + m)k)$ 
  if  $|E| > k^2$  then return false //  $\leq k$  nodes  $\times \leq k$  neighbors
  return vertexCover( $G, k$ )                                           //  $O(2^k k^2)$ 

Insgesamt  $O((n + m)k + 2^k k^2)$            Aufgabe:  $O(n + m + 2^k k^2)$ 
  
```

# Kernbildung für Vertex Cover – Beispiel

**Function** kernelVertexCover( $G = (V, E), k$ ) : Boolean

**if**  $|E| = 0$  **then return** true

**while**  $\exists v \in V : \text{degree}(v) > k$  **do**

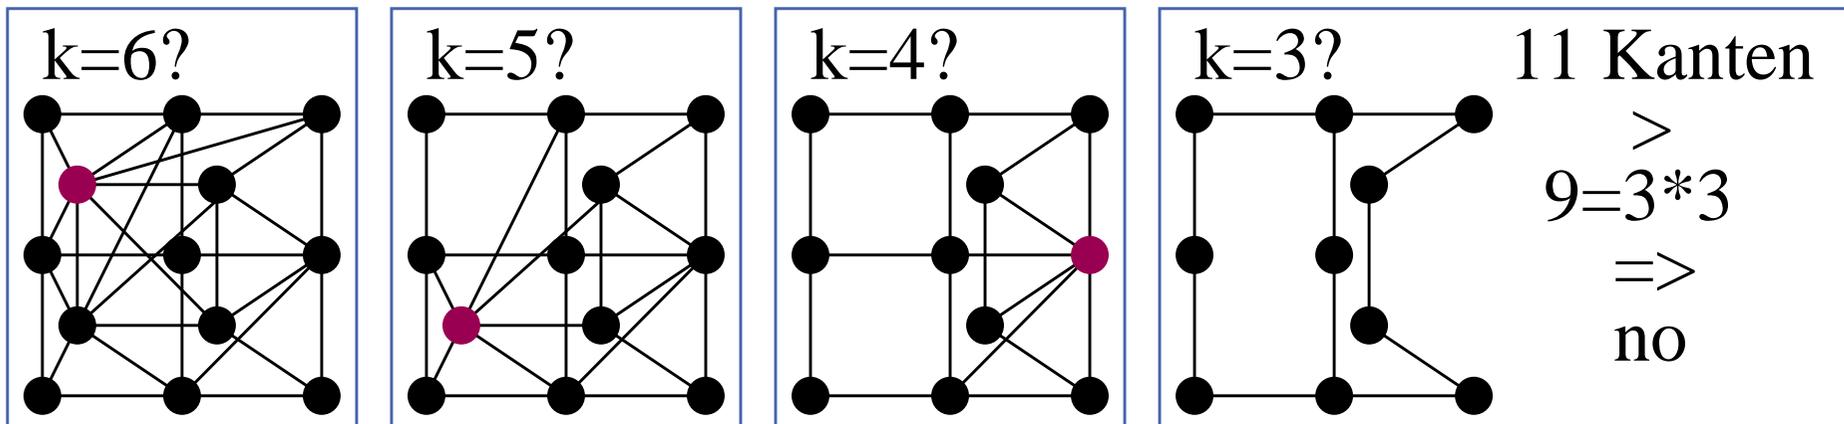
**if**  $k = 0$  **return** false

$G := G - v; \quad k := k - 1$

remove isolated nodes

**if**  $|E| > k^2$  **then return** false

**return** vertexCover( $G, k$ )



# Reduktionsregeln

0: nicht im cover

1: OBdA Nachbar im cover

Aufgabe: vertex cover für Bäume?

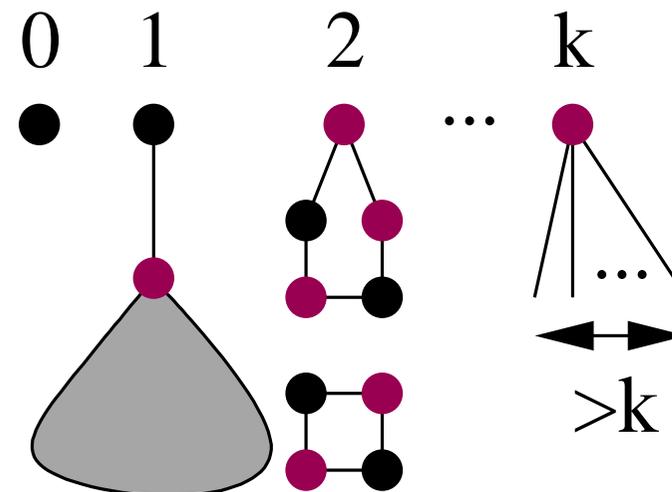
2: geht auch aber komplizierter. Aber,

trivial wenn alle Knoten Grad zwei haben

“Nimm jeden zweiten Knoten”

$> k$ : muss ins cover

Mehr Regeln ?



## Verbesserte tiefenbeschränkte Suche

**Function** vertexCover2( $G = (V, E), k$ ) : Boolean

**if**  $|E| = 0$  **then return** true //  $O(1)$

**if**  $k = 0$  **then return** false //  $O(1)$

**if**  $\exists v \in V : \text{degree}(v) = 1$  **then**

**return** vertexCover2( $G - \text{neighbor}(v), k - 1$ )

**if**  $\exists v \in V : \text{degree}(v) \geq 3$  **then**

**return** vertexCover2( $G - v, k - 1$ )  $\vee$

vertexCover2( $G - \mathcal{N}(v), k - |\mathcal{N}(v)|$ )

**assert** all nodes have degree 2

**return** vertexCoverCollectionOfCycles( $G, k$ )

**Analyse:** Lösung der **Rekurrenz**

$$T(k) = (n + m) + T(k - 1) + T(k - 3) = O((n + m)1.4656^k)$$

$\rightsquigarrow$  benutze **erzeugende Funktionen**

## Weitere Verbesserungen

- Kerne der Größe  $2k$  (mittels Matching-Algorithmen)
- Reduziere Zeit pro rekursivem Aufruf auf  $O(1)$
- Detaillierte Fallunterscheidungen  $\rightsquigarrow$   
kleinere Konstante im exponentiellen Teil

$$\rightsquigarrow O\left(1.2738^k + kn\right)$$

[Chen Kanj Xia 2006]

# Zusammenfassung

- Wichtige Teilklassen NP-harter Probleme können polynomiell lösbar sein
- Kernbildung is wichtige Vor/Zwischenverarbeitungsstrategie für Optimierungsproblem – auch polynomiell lösbar. Zum Beispiel Max-Cardinality matching.
- Brute-force Algorithmen weniger brute-force machen bringt beweisbar exponentielle Beschleunigung.  $\rightsquigarrow$  nichttriviale Analyse- und Entwurfs-Techniken

# 10 Parallele Algorithmen

Schnupperkapitel.

Mehr in der **gleichnamigen Vorlesung**  
sowie im **Vertiefungsfach Parallelverarbeitung**

# 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 ein voll getakteter Prozessor.  
(Leistung  $\approx$  Spannung  $\cdot$  Taktfrequenz)

**Speicherbeschränkungen** von Einzelprozessoren

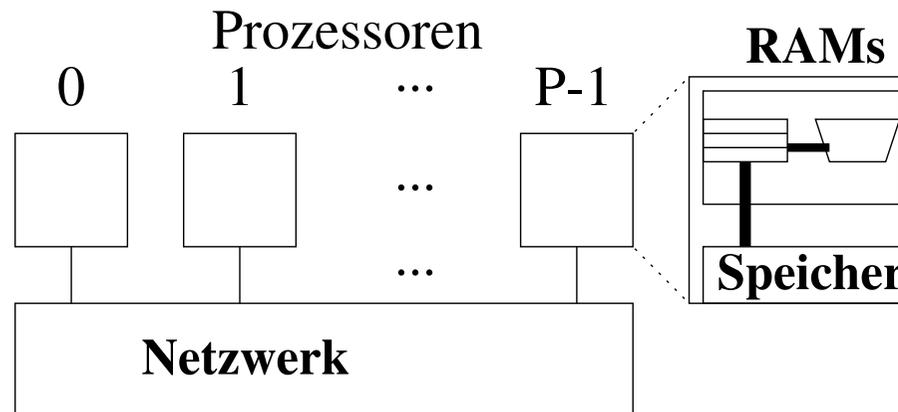
**Kommunikationsersparnis:** wenn Daten verteilt anfallen kann man sie auch verteilt (vor)verarbeiten

# Parallelverarbeitung am ITI Sanders

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

## 10.1 Modell

# Nachrichtengekoppelte Parallelrechner



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

# Kostenmodell für Nachrichtenaustausch

Jedes PE kann

gleichzeitig maximal eine Nachricht senden und empfangen.

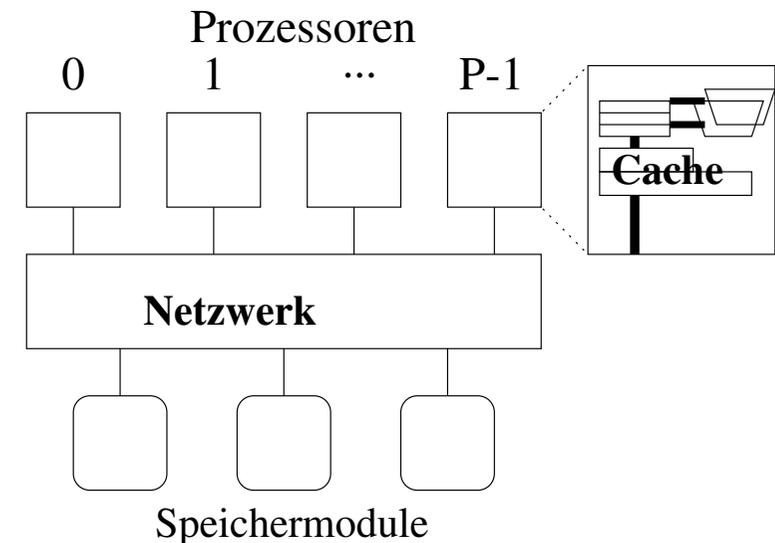
Bei Nachrichtenlänge  $\ell$  dauert das

$$T_{\text{comm}}(\ell) = \alpha + \ell\beta$$

- halbduplex
- Punkt-zu-Punkt
- vollständige Verknüpfung
- i.allg.  $\alpha \gg \beta$  – Alternative: Blockkommunikation analog  
Sekundärspeichermodell

# Warum **kein** (shared memory) Multicore-Modell

- Unklar wie man damit **skalierbaren** Parallelismus erreicht
- Unklares **Kostenmaß** bei Speicherzugriffskonflikten
- Gute Strategie für Parallelprogrammierung: **Verteilt entwerfen, vereint implementieren**



~> mit verteiltem Speicher decken wir den ganzen Bereich vom Multicore-Smartphone zum Superrechner ab und sind noch einigermaßen nah an Cloud, Sensor- oder Peer-to-Peer-Netzen

# Formulierung paralleler Algorithmen

Gleicher Pseudocode wie immer.

Single Program Multiple Data Prinzip.

Der Prozessorindex wird genutzt um die Symmetrie zu brechen.

**Procedure** helloWorldParallel

```
writeLineAtomic "Hallo, I am PE " iProc " out of " p "processing elements"
```

```
Hallo, I am PE 0 out of 3 processing elements
```

```
Hallo, I am PE 2 out of 3 processing elements
```

```
Hallo, I am PE 1 out of 3 processing elements
```

# Analyse paralleler Algorithmen

Im Prinzip nur ein zusätzlicher Parameter:  $p$ .

Finde Ausführungszeit  $T(I, p)$ .

Problem: Interpretation.

Work:  $W = pT(p)$  ist ein Kostenmaß.

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!

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

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

(möglich?).

## 10.2 Beispiel: Assoziative Operationen (=Reduktion)

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

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

in Zeit  $O(\log p)$  berechnen

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

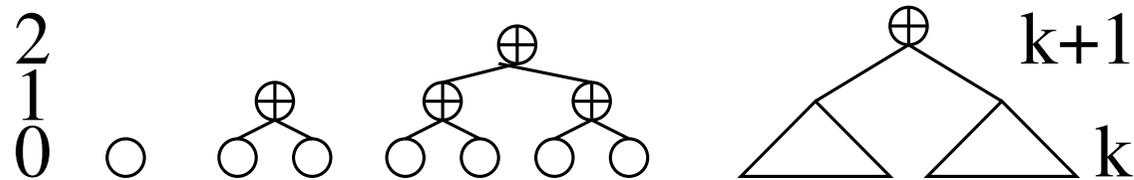
# Grundidee für $p = 2^k$ (oBdA?)

Induktion über  $k$ :

$k = 0$ : trivial

$k \rightsquigarrow k + 1$ :

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



## Pseudocode

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

//Input  $x_i$  located on PE  $i$

active := 1

$s := x_i$

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

**if** active **then**

**if** bit  $k$  of  $i$  **then**

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

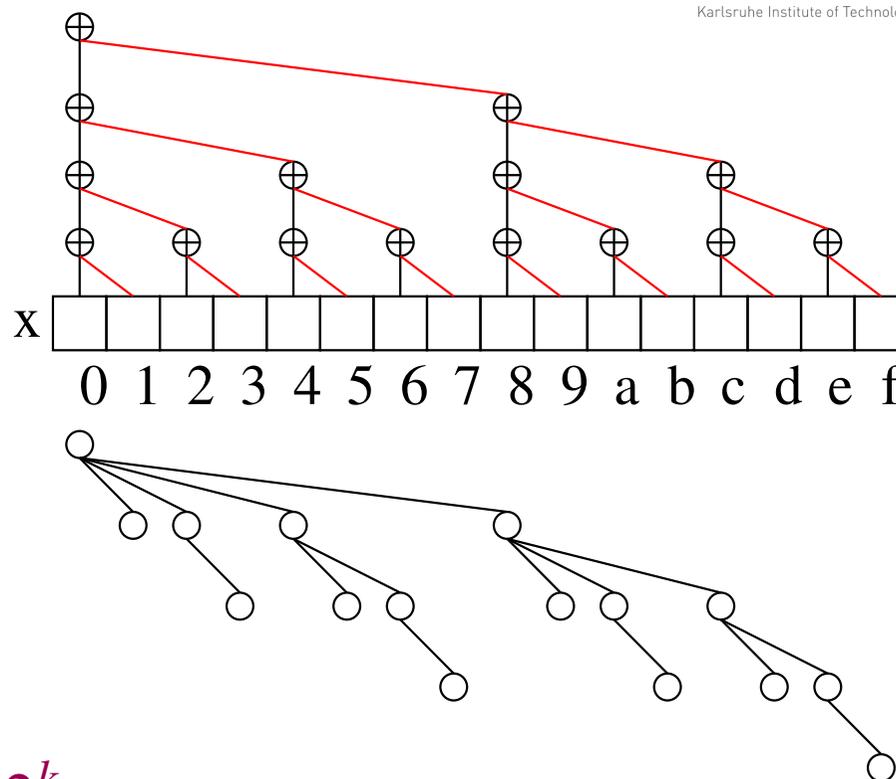
active := 0

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

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

$s := s \oplus s'$

//result is in  $s$  on PE 0



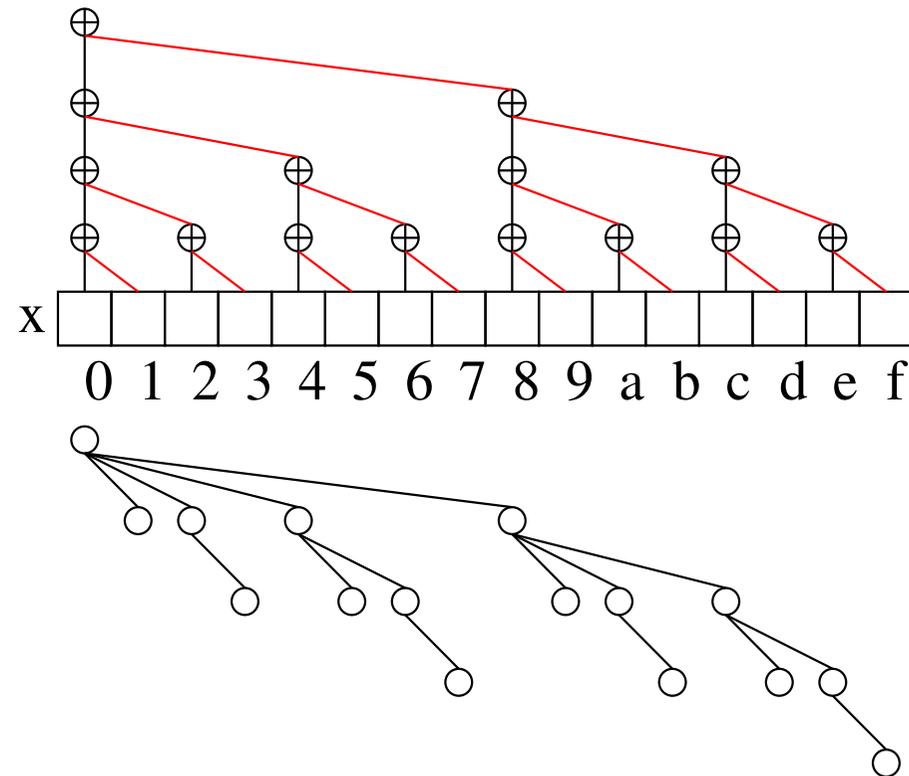
# Analyse

$n$  PEs

Zeit  $O(\log n)$

Speedup  $O(n/\log n)$

Effizienz  $O(1/\log n)$



# Weniger ist Mehr

$p$  PEs

Jedes PE addiert

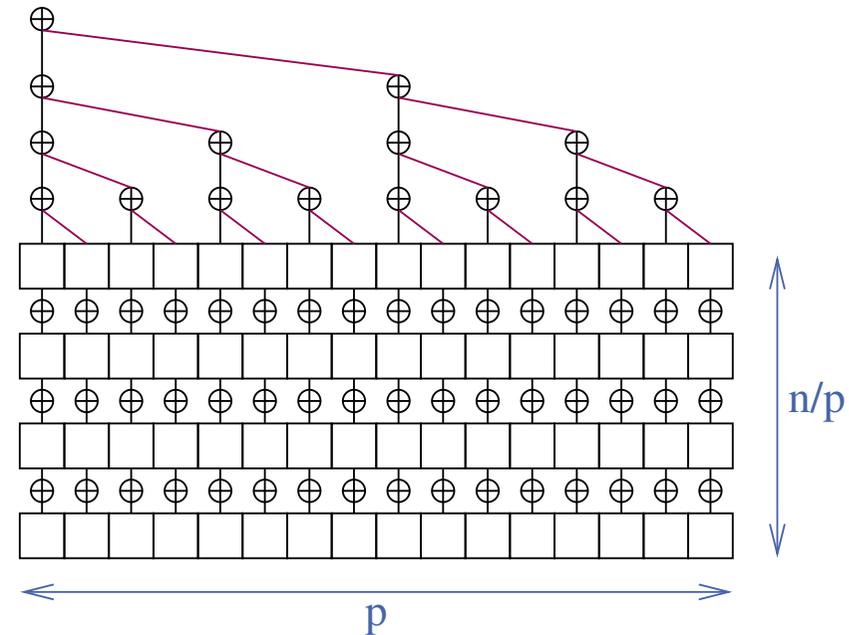
$n/p$  Elemente sequentiell

Dann parallele Summe

für  $p$  Teilsummen

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

Effizienz



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

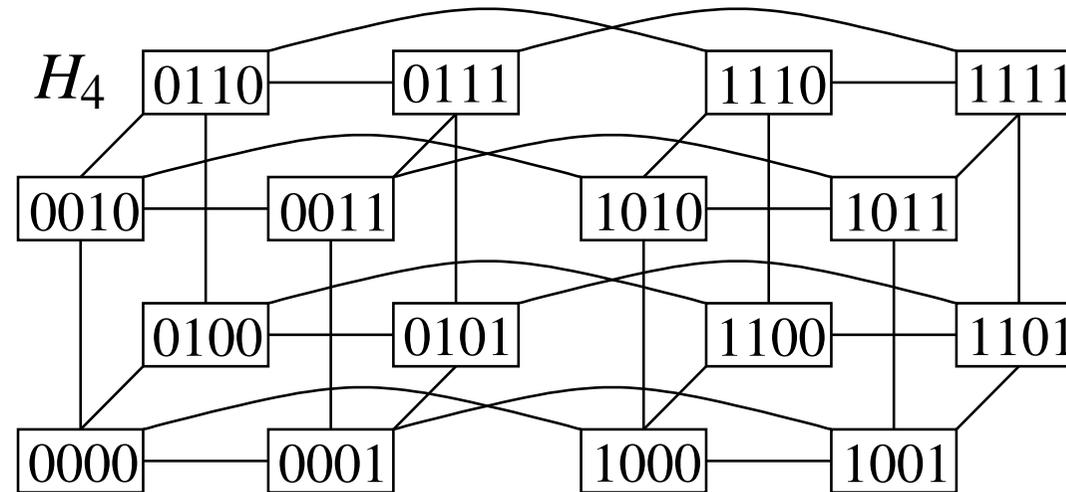
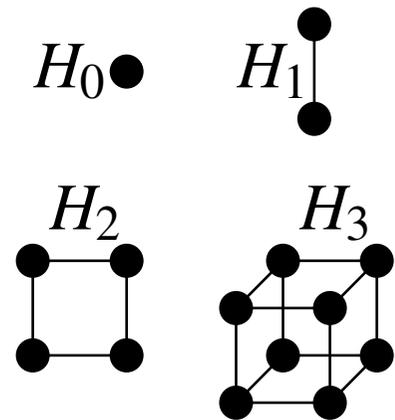
$\approx 1$  falls  $n \gg p \log p$

# Diskussion Reduktionsoperation

- Binärbaum führt zu logarithmischer Ausführungszeit
- Nützlich auf den meisten Modellen
- Brent's Prinzip: Ineffiziente Algorithmen werden durch Verringerung der Prozessorzahl effizient

# Hyperwürfel

hypercube

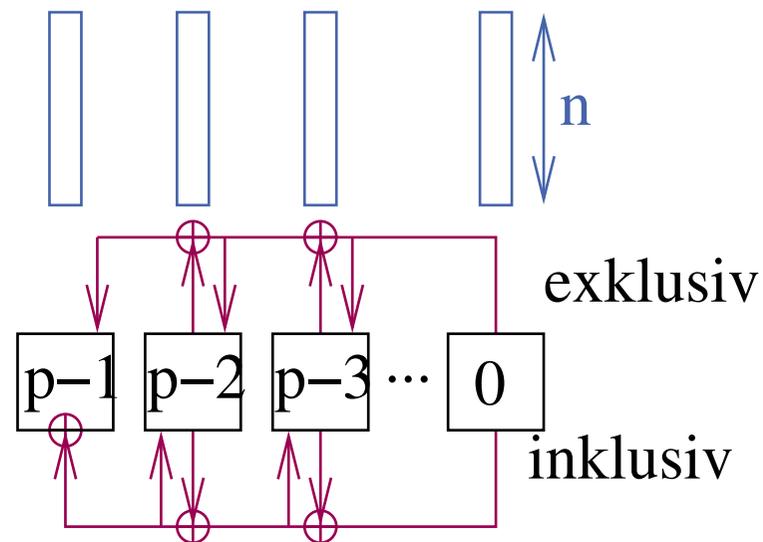


# Präfixsummen

Gesucht

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

(auf PE  $i$ ) Objekte der Länge  $\ell$



inhärent sequentiell ???

# 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**  $\sigma = \bigoplus_{j=i[k..d-1]0^k}^{i[k..d-1]1^k} m@j$

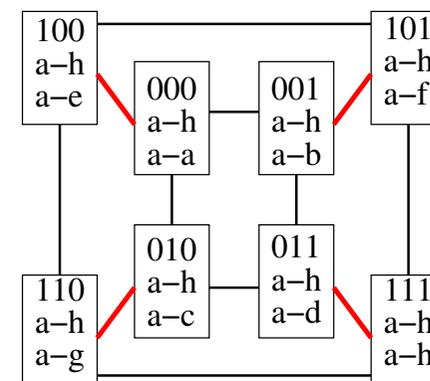
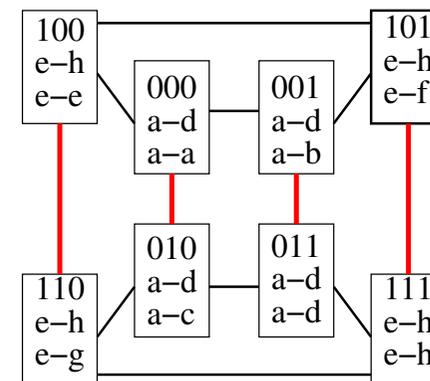
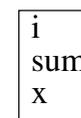
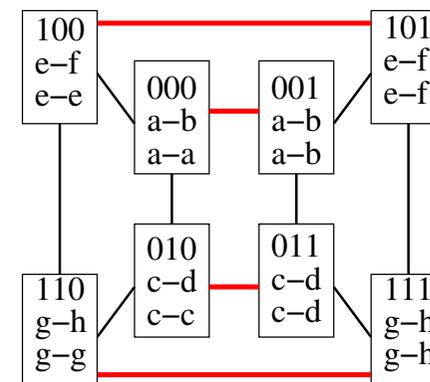
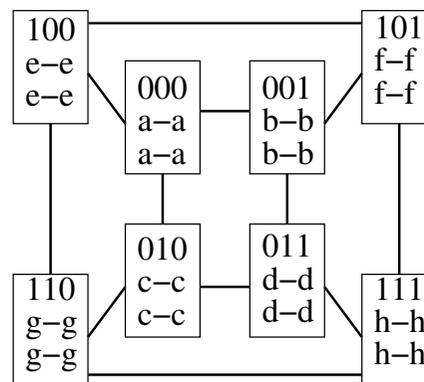
**invariant**  $x = \bigoplus_{j=i[k..d-1]0^k}^i m@j$

$y := \sigma @ (i \text{ xor } 2^k)$  // sendRecv

$\sigma := \sigma \oplus y$

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

**return**  $x$



# Analyse

$$T_{\text{prefix}} = O((\alpha + \ell\beta) \log p)$$

## Problemchen:

Nichtoptimal bei  $\ell\beta > \alpha$  (analog schon bei Reduktion)

siehe Spezialvorlesung

$$\rightsquigarrow O(\alpha \log P + \ell\beta)$$

## 10.3 Sortieren

- Paralleles Quicksort
- Paralleles Mehrwege-Mergesort
- Hier nicht: binäres Mergesort, Radixsort, . . .

# Paralleles Quicksort

## Sequentiell (vereinfacht)

**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**

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

$v := d@r$  // broadcast **pivot**

$f := d \leq v$  // 1 iff  $d$  is on left side, 0 otherwise

$j := \sum_{k=0}^i f@k$  // **prefix sum**, count elements on left side

$p' := j@(p - 1)$  // broadcast, result is border index

**if**  $f$  **then** send  $d$  to PE  $j - 1$

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

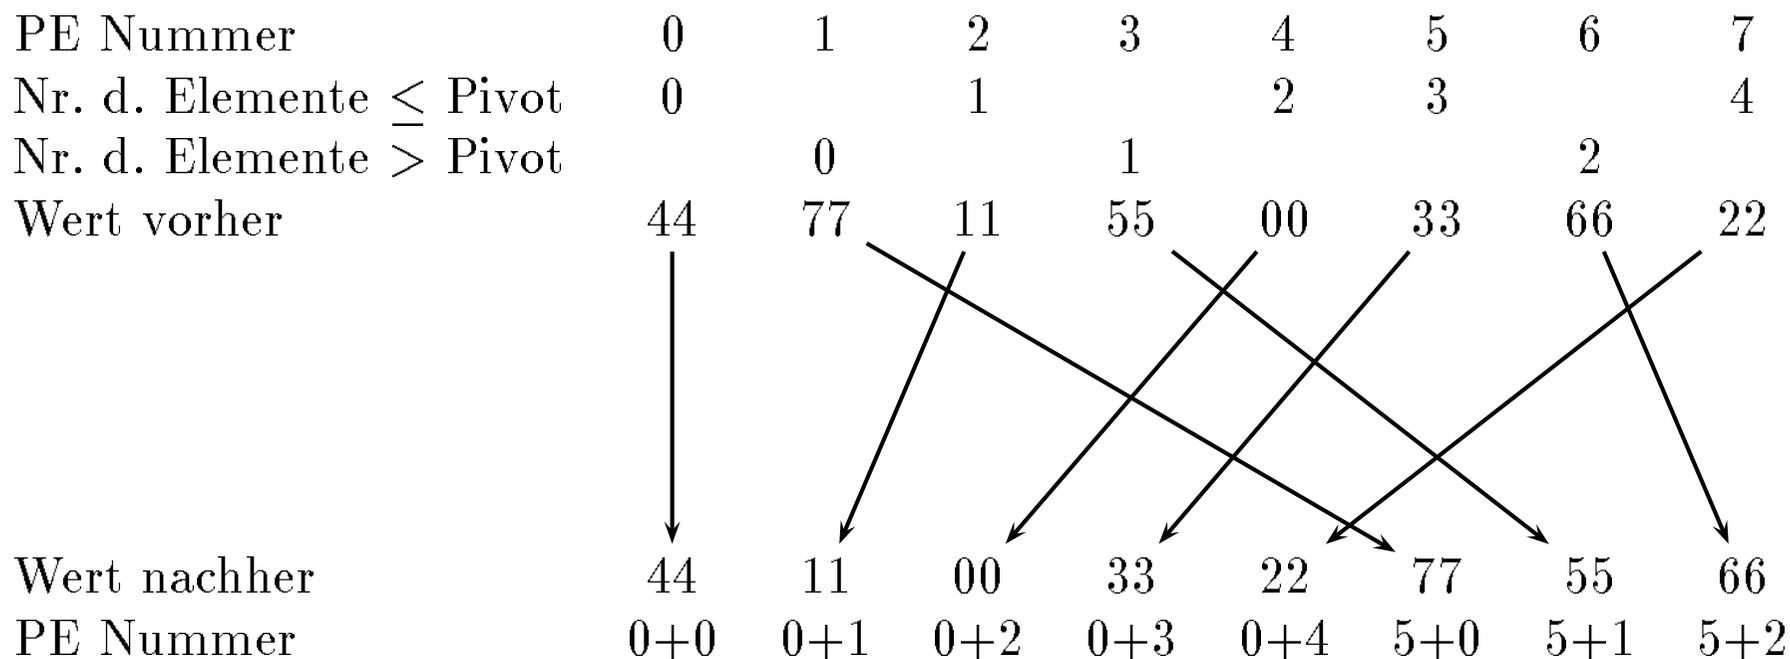
receive  $d$

**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

↪ Zeit  $O(\alpha \log p)$

□ erwartete Rekursionstiefe:  $O(\log p)$

Erwartete Gesamtzeit:  $O(\alpha \log^2 p)$

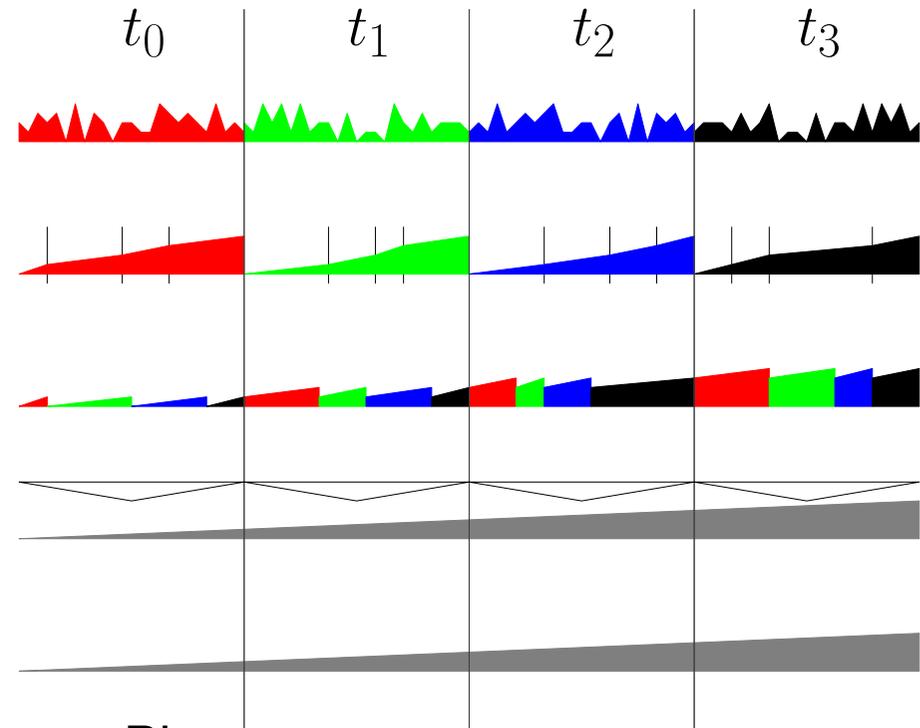
## Verallgemeinerung für $n \gg p$ nach Schema F?

- Jedes PE hat i.allg. „große“ und „kleine“ Elemente.
- Aufteilung geht nicht genau auf
- Präfixsummen weiterhin nützlich
- Unterm Strich ist Zeit  $O\left(\frac{n \log n}{p} + \log^2 p\right)$  möglich
- Bei verteiltem Speicher stört, dass jedes Element  $\Omega(\log p)$  mal transportiert wird.

$$\rightsquigarrow \dots \rightsquigarrow \text{Zeit } O\left(\frac{n}{p}(\log n + \beta \log p) + \alpha \log^2 p\right)$$

# Paralleles Sortieren durch Mehrwegemischen

1.  $p$  Prozessoren sortieren  
je  $n/p$  Elemente lokal
2. Finde pivots so dass  
 $n/p$  Elemente zwischen  
zwei benachbarten pivots liegen
3. Jeder Prozessor macht  
Mehrwegemischen für alle  
Elemente zwischen zwei benachbarten Pivots.

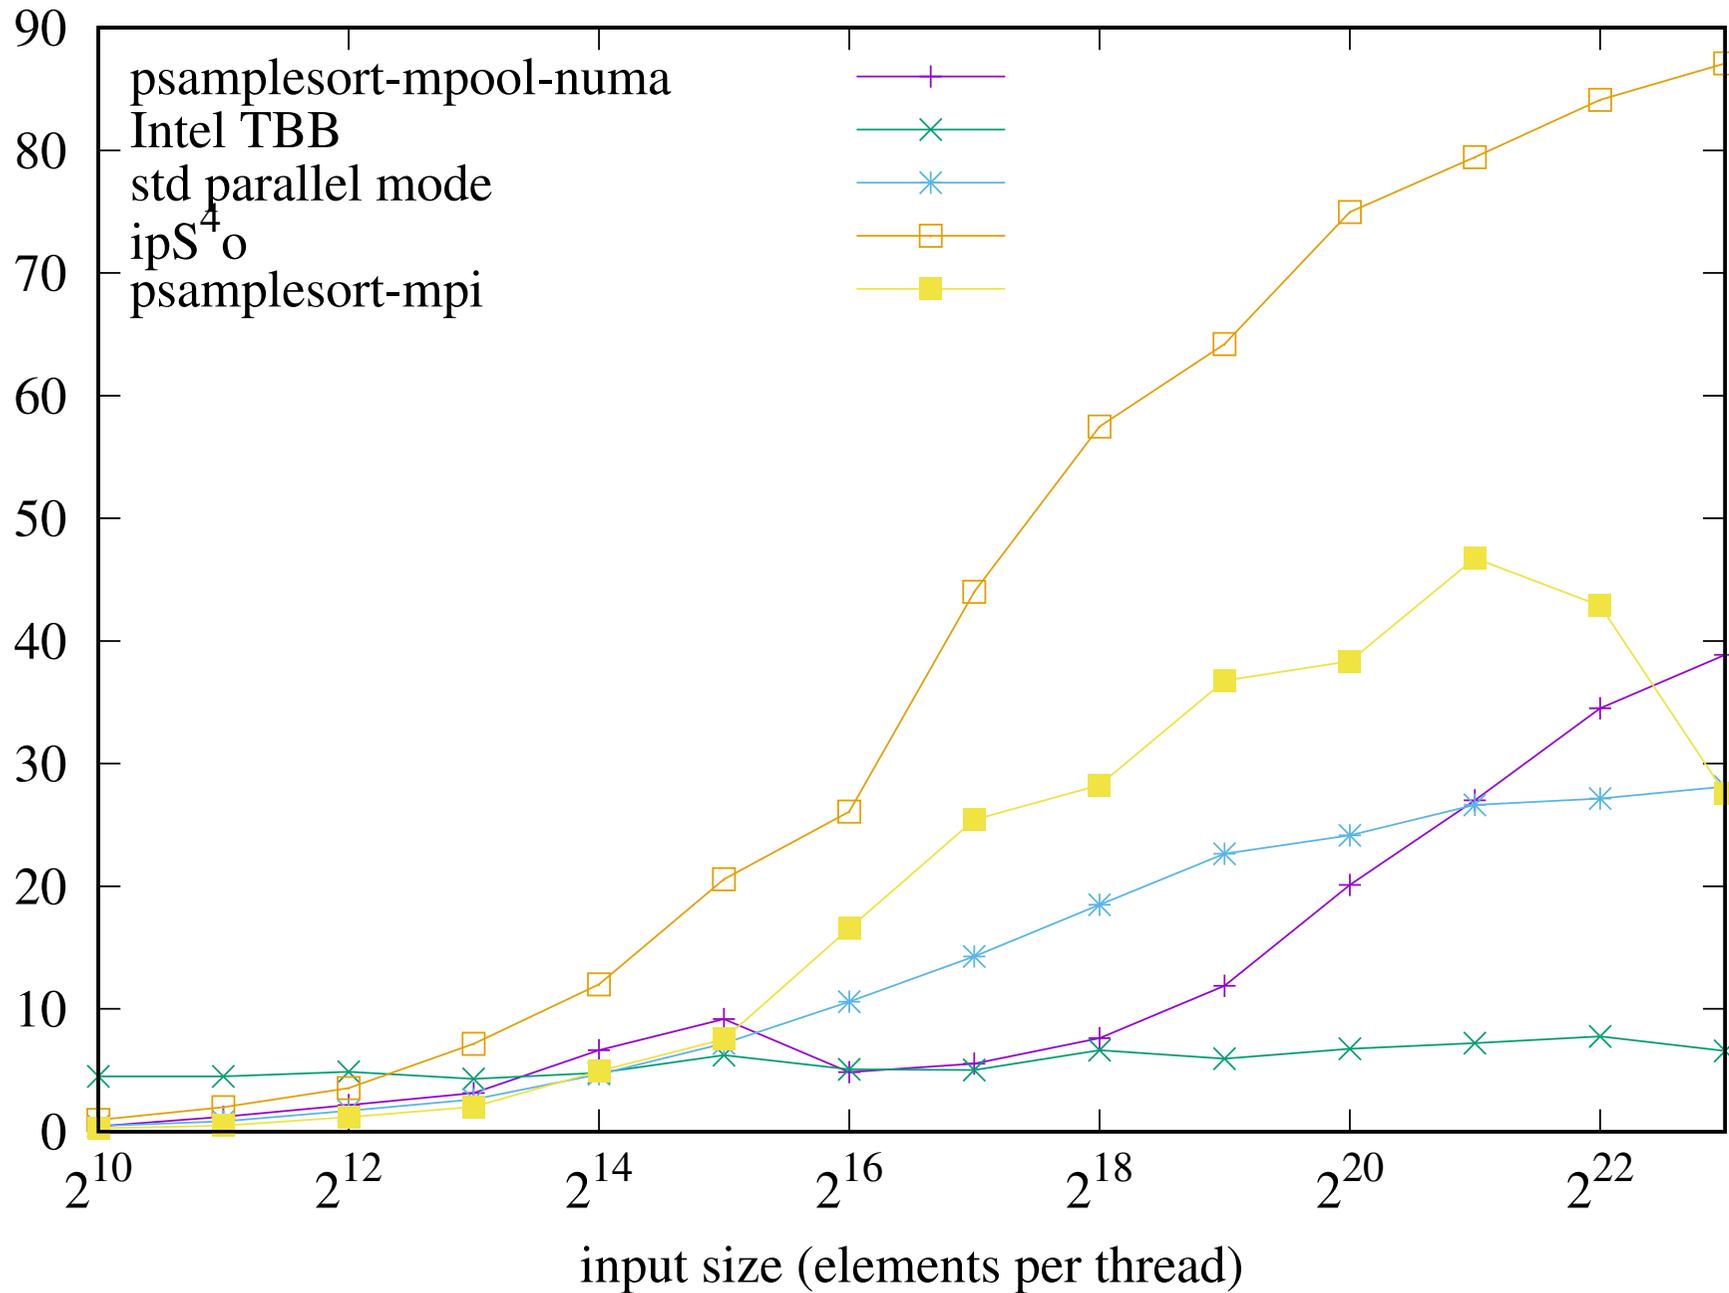


Mehr in "Parallele Algorithmen"

## Mehr zu parallelem Sortieren

- Theoretikeralgorithmen mit Laufzeit  $O(\log p)$  bei  $p = n$
- Praktikable Algorithmen mit Laufzeit  $O(\log p)$  für  $n = O(\sqrt{p})$  –  
wenn schnell wichtiger als effizient ist, z.B. base case
- Sample sort:  $k$ -Wegeverallgemeinerung von quicksort
- Paralleles externes Sortieren

# Experiments Speedup on 4 × Intel E7-8890 v3 – 72 cores





# Mehr zu parallelen Algorithmen – Parallelisierung der Basic Toolbox ?

Verteilte Hashtabellen: geht oft teuer  $\rightsquigarrow$  [Maier S Dementiev 16]

Prioritätslisten, Suchbäume: ähnliches Problem. Am ehesten **batched updates**  $\rightsquigarrow$  [Hübschle-Schn. S Müller 16][Akhremtsev S 16]

BFS: OK bei kleinem Graphdurchmesser

DFS:  $\approx$  inhärent nichtparallelisierbar

kürzeste Wege: ähnlich BFS. Aber all-to-all, Vorberechnungen OK,  
multiobjective OK [Mandow S 13]

MST: **Ja!** Aber u.U. große konstante Faktoren

Optimierungstechniken: dynamische Programmierung OK. Greedy???

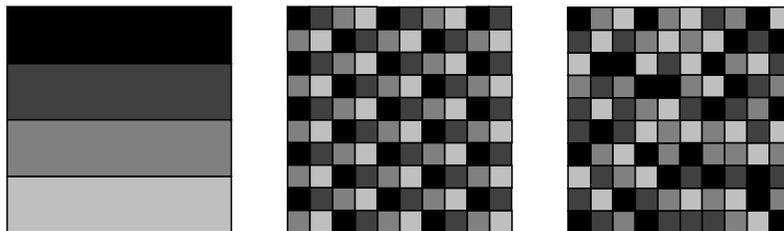
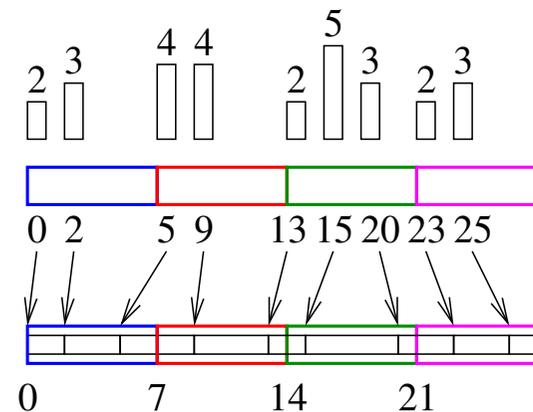
LP schwierig, Metaheuristiken teils OK

# Mehr zu parallelen Algorithmen – Die parallele Basic Toolbox

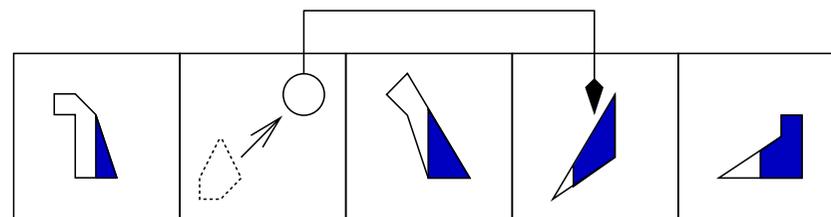
- Kollektive Kommunikation: **Reduktion**, **Präfixsumme**, allg. Nachrichtenaustausch, Gossiping,...

- Lastverteilung

- statisch/dynamisch
- bekannte/unbekannte Jobgrößen
- zentralisiert/vollverteilt



processed by:  =PE 0  =PE 1  =PE 2  =PE 3

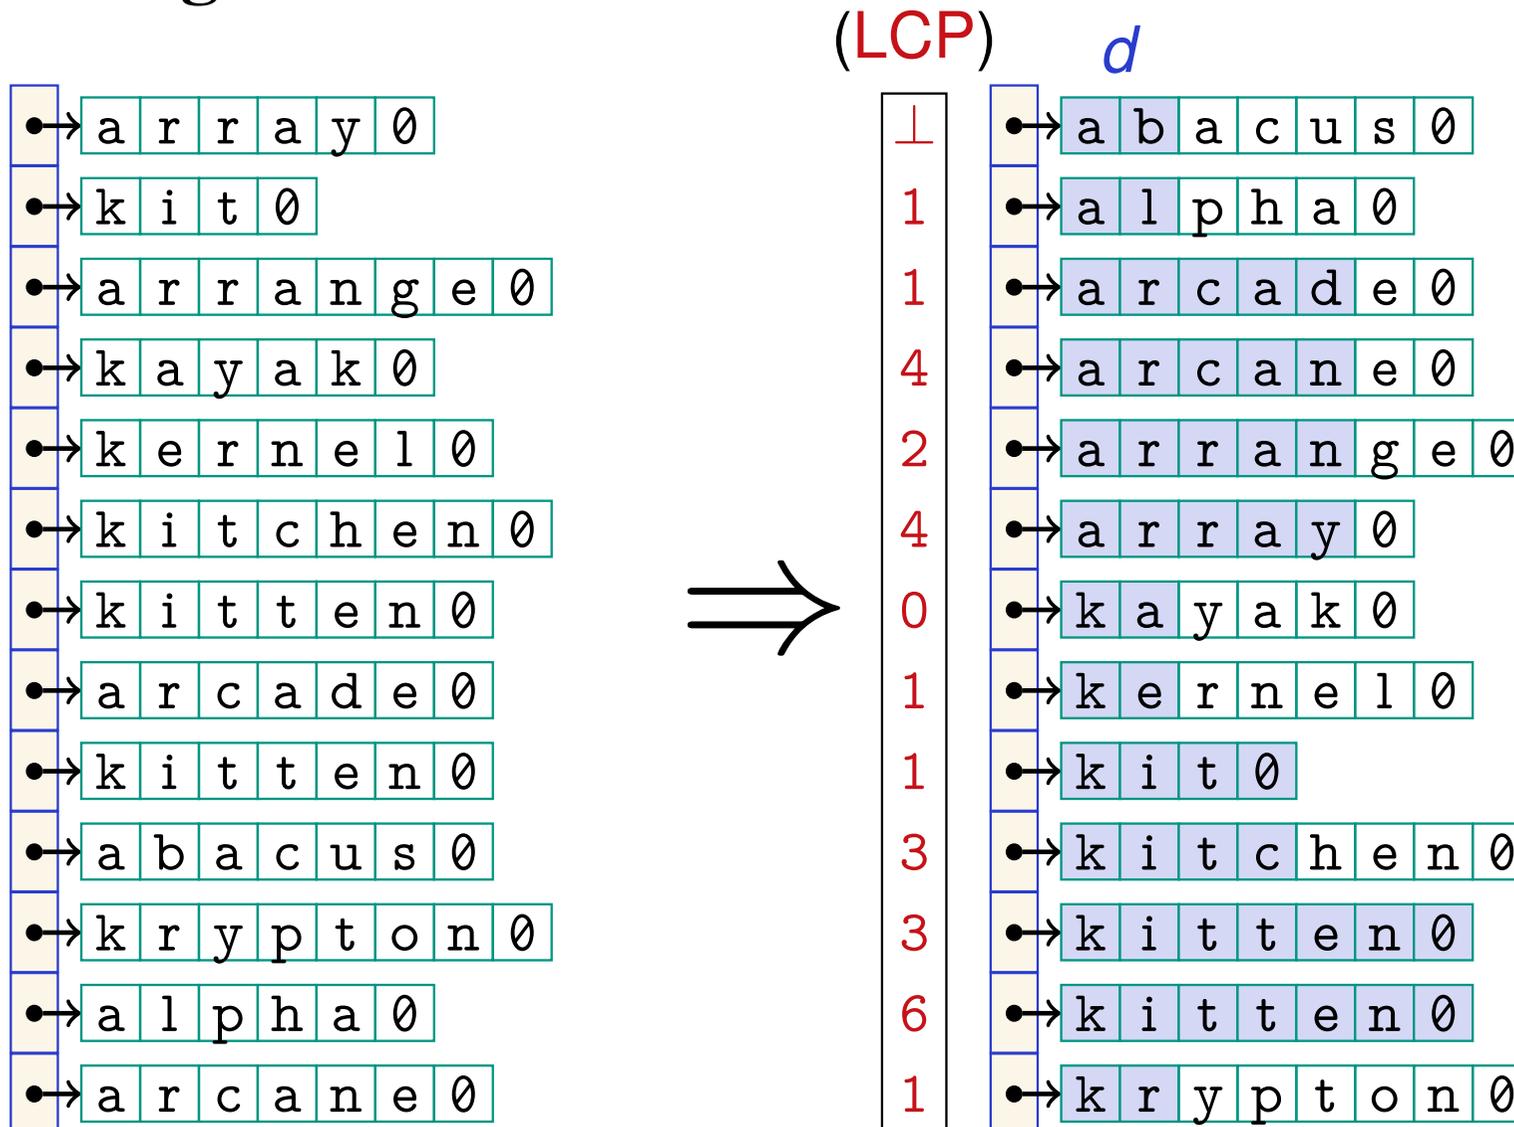


# 11 Stringology

## (Zeichenkettenalgorithmen)

- Strings sortieren
- Patterns suchen
  - Pattern vorverarbeiten
  - Text vorverarbeiten
    - \* Invertierte Indizes
    - \* Suffix Trees / Suffix Arrays
- Datenkompression
- Pattern suchen in komprimierten Indizes

# Strings Sortieren



Eingabe:  $n$  Strings mit  $N$  Zeichen insgesamt.

# Sortieren: Most Significant Digit Radix Sort

a r r a y

k i t

a r r a n g e

k a y a k

k e r n e l

k i t c h e n

k i t t e n

a r c a d e

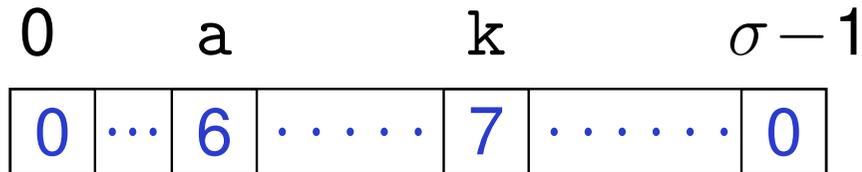
k i t e

a b a c u s

k r y p t o n

a l p h a

a r c a i c



# Sortieren: Most Significant Digit Radix Sort

array  
kit  
arrange  
kayak  
kernel  
kitchen  
kitten  
arcade  
kite  
abacus  
krypton  
alpha  
arcaic

0            a            k             $\sigma - 1$

0	...	6	.....	7	.....	0
---	-----	---	-------	---	-------	---

0	...	0	6	...	6	13	.....	13	13
---	-----	---	---	-----	---	----	-------	----	----

# Sortieren: Most Significant Digit Radix Sort

a r r a y

k i t

a r r a n g e

k a y a k

k e r n e l

k i t c h e n

k i t t e n

a r c a d e

k i t e

a b a c u s

k r y p t o n

a l p h a

a r c a i c

0            a                    k                             $\sigma - 1$

0	...	6	.....	7	.....	0
---	-----	---	-------	---	-------	---

0	...	0	6	...	6	13	...	13	13
---	-----	---	---	-----	---	----	-----	----	----

# Sortieren: Most Significant Digit Radix Sort

a r r a y

a r r a n g e

a r c a d e

a b a c u s

a l p h a

a r c a i c

k i t

k a y a k

k e r n e l

k i t c h e n

k i t t e n

k i t e

k r y p t o n

0            a                    k                     $\sigma - 1$

0	...	6	.....	7	.....	0
---	-----	---	-------	---	-------	---

0	...	0	6	...	6	13	...	13	13
---	-----	---	---	-----	---	----	-----	----	----

- Laufzeit:  
 $\mathcal{O}(d + r\sigma + n \log \sigma)$
- Varianten: out-of-place und in-place!

# Sortieren: Most Significant Digit Radix Sort

a	r	r	a	y		
k	i	t				
a	r	r	a	n	g	e
k	a	y	a	k		
k	e	r	n	e	l	
k	i	t	c	h	e	n
k	i	t	t	e	n	
a	r	c	a	d	e	
k	i	t	e			
a	b	a	c	u	s	
k	r	y	p	t	o	n
a	l	p	h	a		
a	r	c	a	i	c	

0	a	k	$\sigma - 1$	
0	...	6	..... 7	..... 0

0	...	0	6	...	6	13	.....	13	13
---	-----	---	---	-----	---	----	-------	----	----

$p_1$	0	...	2	.....	3	.....	0
$p_2$	0	...	2	.....	3	.....	0
$p_3$	0	...	2	.....	1	.....	0

# Sortieren: Most Significant Digit Radix Sort

a	r	r	a	y		
k	i	t				
a	r	r	a	n	g	e
k	a	y	a	k		
k	e	r	n	e	l	
k	i	t	c	h	e	n
k	i	t	t	e	n	
a	r	c	a	d	e	
k	i	t	e			
a	b	a	c	u	s	
k	r	y	p	t	o	n
a	l	p	h	a		
a	r	c	a	i	c	

0	a	k	$\sigma - 1$			
0	...	6	.....	7	.....	0

0	...	0	6	...	6	13	.....	13	13
---	-----	---	---	-----	---	----	-------	----	----

$p_1$	0	...	2	.....	3	.....	0
$p_2$	0	...	2	.....	3	.....	0
$p_3$	0	...	2	.....	1	.....	0

$p_1$	0	...	0	6	...	6	13	.....	13	13
$p_2$	0	...	2	6	...	9	13	.....	13	
$p_3$	0	...	4	6	...	12	13	.....	13	

# Sortieren: Most Significant Digit Radix Sort

---

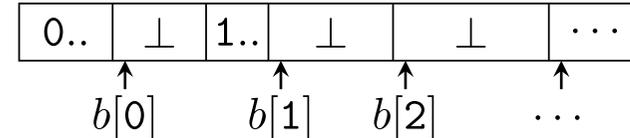
**Algorithm :** Sequential Radix Sort “CE0”, adapted from [KR08; Ran07]

---

```

1 Function RadixSortCE0( $\mathcal{S}, h$ )
   Input :  $\mathcal{S} = [s_0, \dots, s_{n-1}]$  an array of  $n$  strings with common prefix  $h$ .
2    $c := [0, \dots, 0]$  // Allocate  $|\Sigma|$  integer counters initialized with zero,
3   for  $i = 0, \dots, n - 1$  do  $c[s_i[h]]++$  // and count character occurrences.
4    $b := [0, \perp, \dots, \perp]$  // Calculate exclusive prefix sum of counters
5   for  $i = 1, \dots, n - 1$  do  $b[i] := b[i - 1] + c[i - 1]$  // as bucket pointers.
6    $\mathcal{T} := \text{allocate}(n, \text{string pointer})$  // Allocate temporary array for sorted output.
7   for  $i = 0, \dots, n - 1$  do // Reorder
8      $\mathcal{T}[b[s_i[h]]] := \text{move}(s_i)$  // into
9      $b[s_i[h]]++$  // buckets
10   $\text{copy}(\mathcal{T} \rightarrow \mathcal{S}), \text{deallocate}(\mathcal{T}, b)$ .
11   $x := c[0]$  // Track beginning of bucket as  $x$ ,
12  for  $i = 1, \dots, |\Sigma| - 1$  do // recurse into every unfinished bucket,
13     $\text{StringSort}(\mathcal{S}[x .. x + c[i]], h + 1)$  // except for the first (zero-termination),
14     $x := x + c[i]$  // which contains all fully sorted strings.
   Output : The array  $\mathcal{S}$  is fully sorted lexicographically.

```



# Strings Sortieren: Multikey Quicksort

Auch: MKQS / ternary quicksort

**Function** mkqSort( $S$  : Sequence **of** String,  $\ell$  :  $\mathbb{N}$ ) : Sequence **of** String

**assert**  $\forall e, e' \in S : e[1..\ell - 1] = e'[1..\ell - 1]$

**if**  $|S| \leq 1$  **then return**  $S$  // base case

pick  $p \in S$  uniformly at random // pivot string

**return** concatenation of  
 $\text{mkqSort}(\langle e \in S : e[\ell] < p[\ell] \rangle, \ell)$ ,  
 $\text{mkqSort}(\langle e \in S : e[\ell] = p[\ell] \rangle, \ell + 1)$ , and  
 $\text{mkqSort}(\langle e \in S : e[\ell] > p[\ell] \rangle, \ell)$

- Laufzeit:  $O(|S| \log |S| + \sum_{t \in S} |t|)$
- genauer:  $O(|S| \log |S| + d)$  ( $d$ : Summe der **eindeutigen Präfixe**)
- Übung: **in-place!**

# Strings Sortieren: Multikey Quicksort

S A A L  
B I E N E  
E H R E  
H A U S  
A R M  
M I E T E  
T A S S E  
M O R D  
H A N D  
S E E  
H U N D  
H A L L E  
N A C H T

# Strings Sortieren: Multikey Quicksort

S A A L  
B I E N E  
E H R E  
H A U S  
A R M  
M I E T E  
T A S S E  
M O R D  
**H** A N D  
S E E  
H U N D  
H A L L E  
N A C H T

*p*

# Strings Sortieren: Multikey Quicksort

B I E N E

E H R E

A R M

H A U S

H A N D

H U N D

H A L L E

S A A L

T A S S E

M I E T E

M O R D

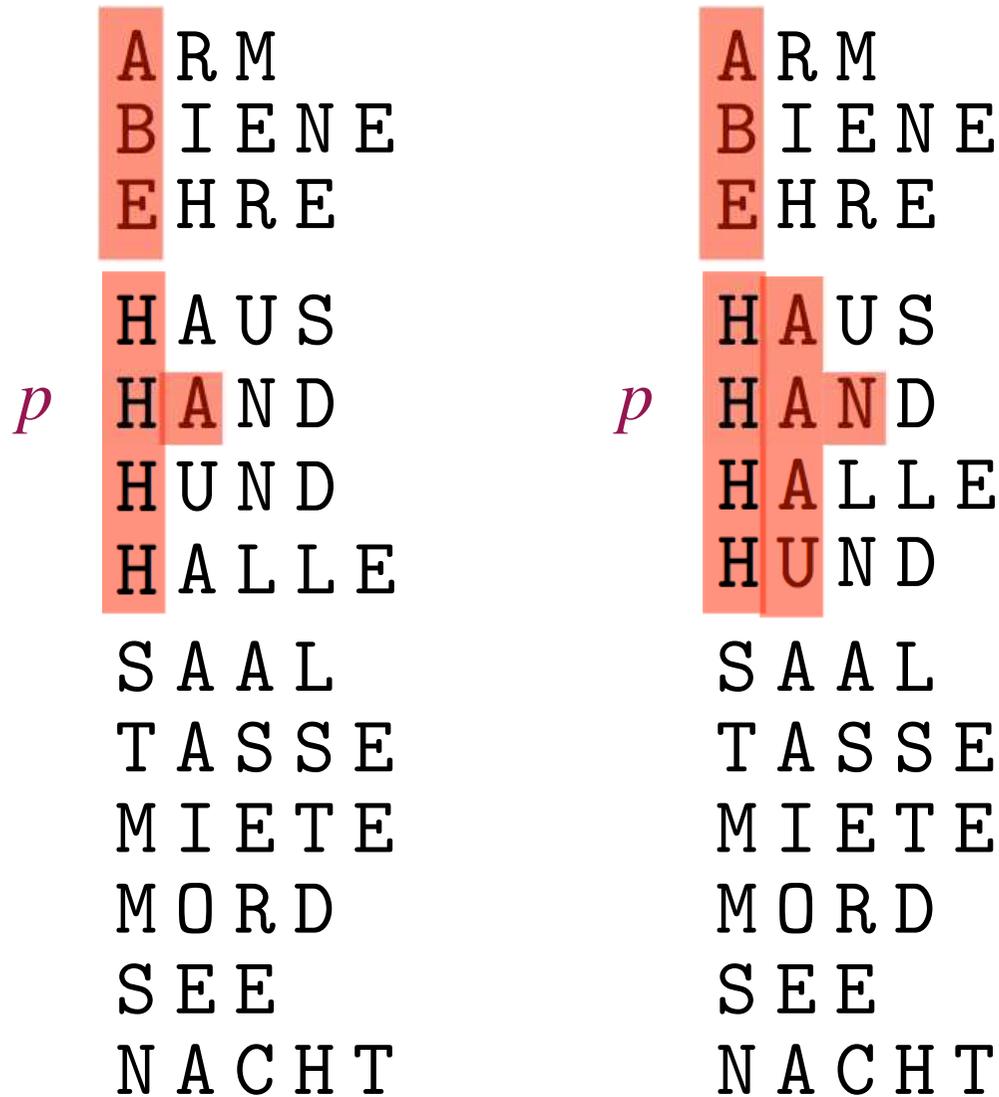
S E E

N A C H T

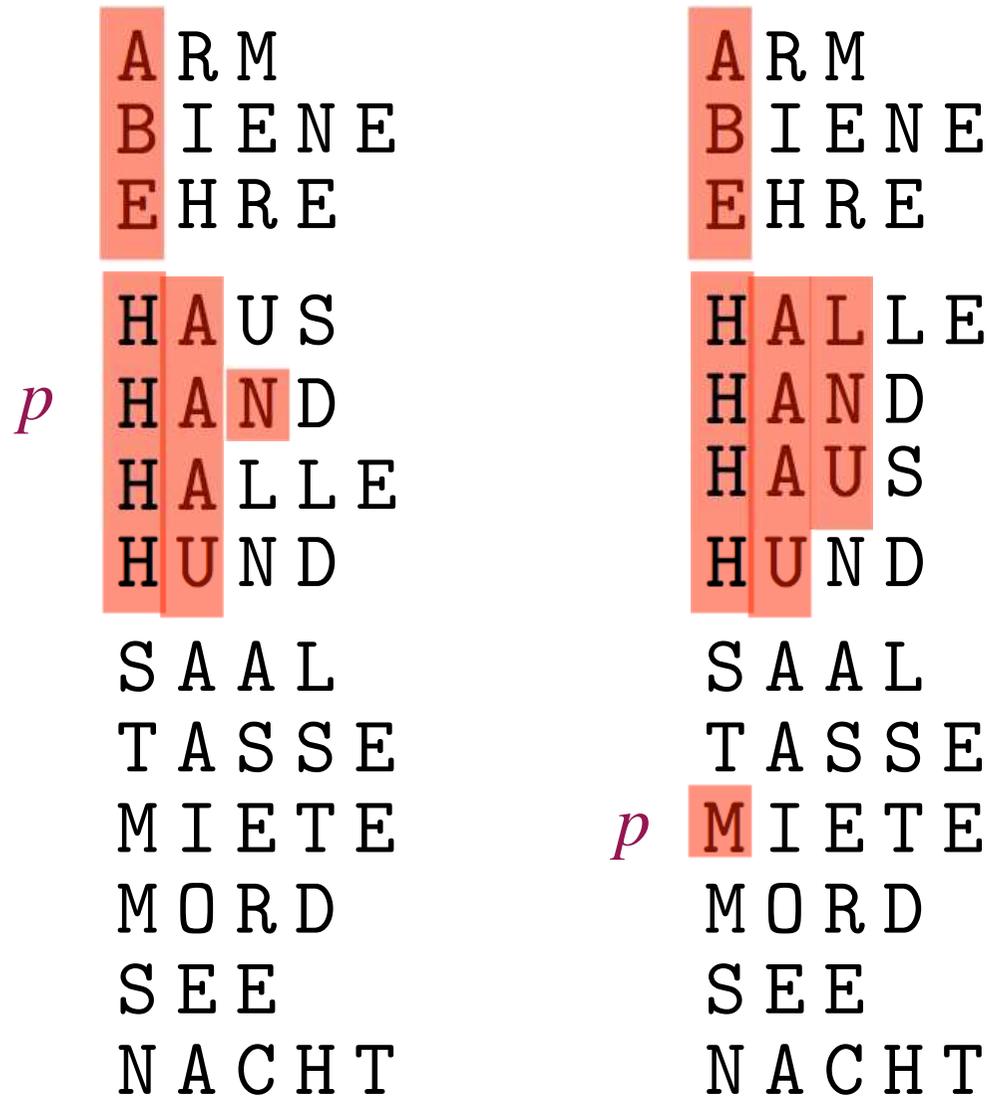
# Strings Sortieren: Multikey Quicksort

	B I E N E		A R M
<i>p</i>	E H R E		B I E N E
	A R M		E H R E
	H A U S		H A U S
	H A N D	<i>p</i>	H A N D
	H U N D		H U N D
	H A L L E		H A L L E
	S A A L		S A A L
	T A S S E		T A S S E
	M I E T E		M I E T E
	M O R D		M O R D
	S E E		S E E
	N A C H T		N A C H T

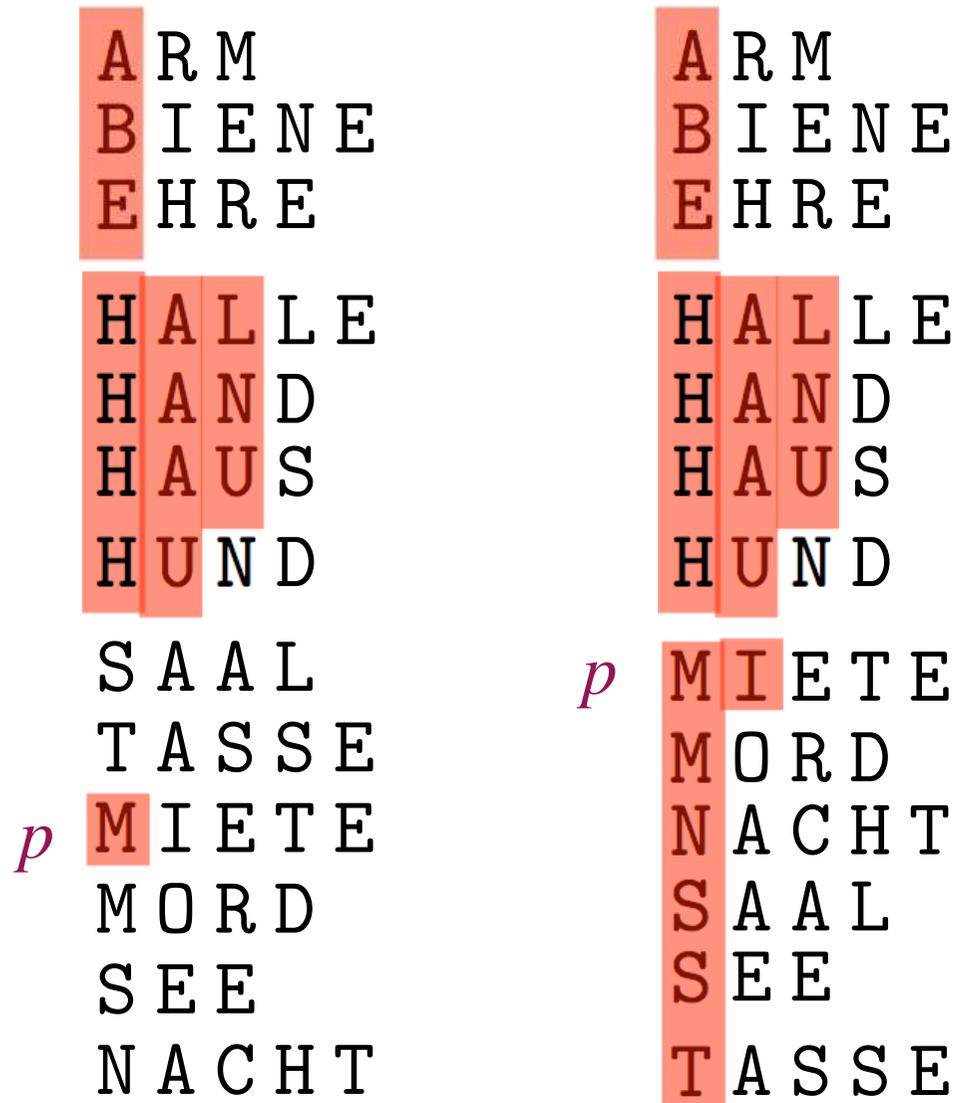
# Strings Sortieren: Multikey Quicksort



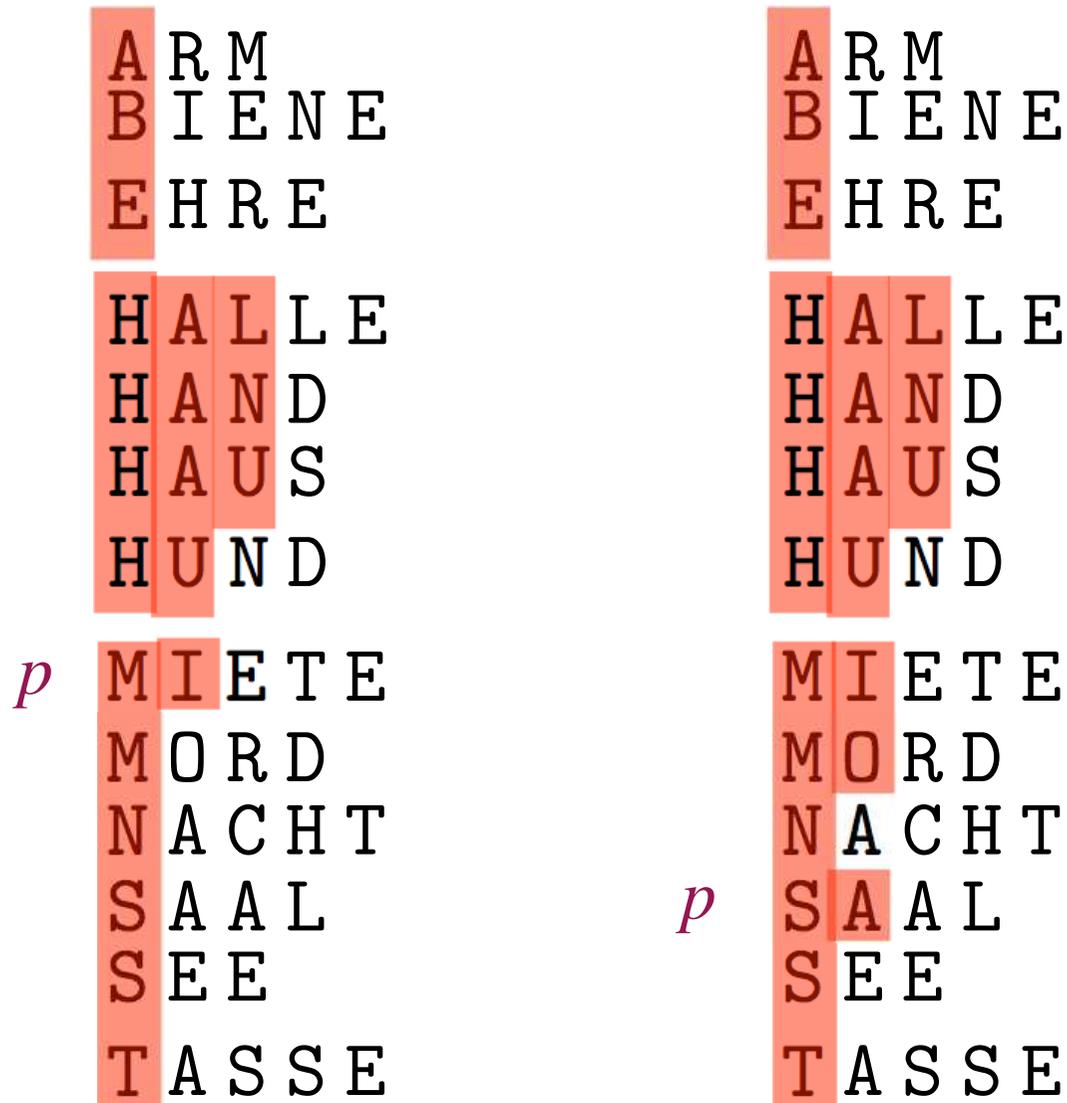
# Strings Sortieren: Multikey Quicksort



# Strings Sortieren: Multikey Quicksort



# Strings Sortieren: Multikey Quicksort



## Strings Sortieren (ohne Endzeichen)

**Function** mkqSort( $S$  : Sequence **of** String,  $\ell$  :  $\mathbb{N}$ ) : Sequence **of** String

**if**  $|S| \leq 1$  **then return**  $S$

$S_{\perp} \leftarrow \langle e \in S : |e| = \ell \rangle$ ;  $S \leftarrow S \setminus S_{\perp}$

select pivot  $p \in S$

$S_{<} \leftarrow \langle e \in S : e[\ell] < p[\ell] \rangle$

$S_{=} \leftarrow \langle e \in S : e[\ell] = p[\ell] \rangle$

$S_{>} \leftarrow \langle e \in S : e[\ell] > p[\ell] \rangle$

**return** concatenation of  $S_{\perp}$ ,

mkqSort( $S_{<}, \ell$ ),

mkqSort( $S_{=}, \ell + 1$ ), and

mkqSort( $S_{>}, \ell$ )

# Strings Sortieren – Laufzeitanalyse

Hauptarbeit in den Buchstabenvergleichen. Zwei Fälle:

- $e[\ell] = p[\ell]$ : Ordne den Vergleich dem Zeichen  $e[\ell]$  zu.
  - $e[\ell]$  wird danach nicht mehr betrachtet (Rekursion mit  $\ell + 1$ )
  - Maximale Vergleichszahl pro String  $e$ ? Maximale Länge des längsten gemeinsamen Präfix von  $e$  mit  $e' \in S$ .
  
- $e[\ell] \neq p[\ell]$ : Ordne den Vergleich dem String  $e$  zu.
  - $e$  wird zu  $S_{<}$  oder  $S_{>}$  zugeordnet. Mit optimaler Pivotwahl sind beide Mengen höchstens  $|S|/2$ .
  - Nach höchstens  $\log |S|$  Schritten ist  $e$  richtig sortiert.

# Strings Sortieren: Algorithmen-Übersicht

## Sequentielle Basis-Algorithmen

- Radix Sort  $O(d + n \log \sigma)$  [McIlroy et al. '95]
- Multikey Quicksort  $O(d + n \log n)$  exp. [Bentley, Sedgewick '97]
- Burstsart  $O(d + n \log \sigma)$  exp. [Sinha, Zobel '04]
- Binary LCP-Mergesort  $O(d + n \log n)$  [Ng, Kakehi '08]

## Theoretische Parallele Algorithmen

- “Optimal Parallel String Algorithms: ...” [Hagerup '94]  
 $O(\log N / \log \log N)$  time and  $O(N \log \log N)$  work on CRCW PRAM

## Praktische Parallele und neue Basis-Algorithmen

- Parallel Super Scalar String Sample Sort (pS<sup>5</sup>) [B, Sanders, ESA'13]
- Parallel  $K$ -way LCP-aware Merge(sort) [B, et al. Algorithmica'17]

# Vergleich Sequentielle Algorithmen

**Experiment [B'18]:** Vergleich von 39 sequentiellen String Sorting Algorithmen und getunten Varianten auf **sieben Eingaben** und **sechs Maschinen**.

Unten: Repräsentative Auswahl der Basis-Algorithmen.

Rang	Algorithmus	GeoM	Rang	Algorithmus	GeoM
1	KR.radixsort-CE6	1.27	10	B.Seq-S <sup>5</sup> -UI	1.67
2	KRB.radixsort-CE3s	1.28	14	R.burstersort-vec	1.72
3	KR.radixsort-CE7	1.28	16	SZ.burstersortA	1.78
4	KRB.radixsort-CI3s	1.33	23	BS.mkqs	2.36
5	R.mkqs-cache8	1.34	28	NK.LCP-Mergesort	2.96
6	KR.radixsort-CE2	1.49	34	MBM.radixsort	4.82
7	KR.radixsort-DB	1.55	35	AN.ForwardRadix16	4.88

## Ergebnisse:

- **Hardware**-spezifische **Beschleunigungen** sind sehr wichtig.
- **Cachen** von Zeichen reduziert Random-Zugriffe aber kostet Speicher.

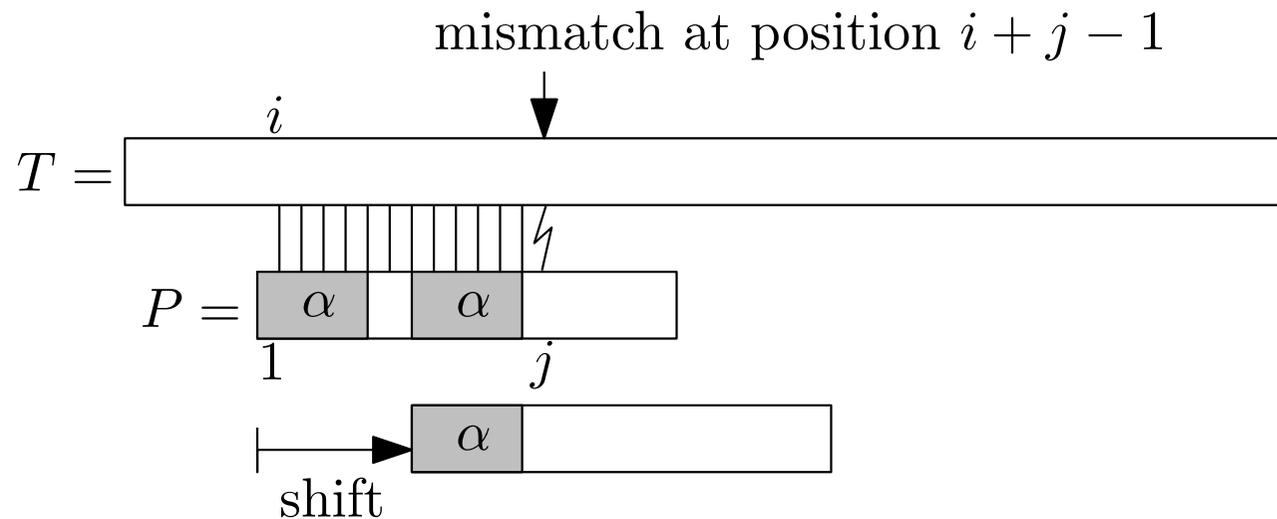
# Naives Pattern Matching

- Aufgabe: Finde alle Vorkommen von  $P$  in  $T$ 
  - $n$ : Länge von  $T$
  - $m$ : Länge von  $P$
- naiv in  $O(nm)$  Zeit

```
 $i, j := 1$  // indexes in  $T$  and  $P$   
while  $i \leq n - m + 1$   
    while  $j \leq m$  and  $t_{i+j-1} = p_j$  do  $j++$  // compare characters  
    if  $j > m$  then print " $P$  occurs at position  $i$  in  $T$ "  
     $i++$  // advance in  $T$   
     $j := 1$  // restart
```

# Knuth-Morris-Pratt (1977)

- besserer Algorithmus in  $O(n + m)$  Zeit
- Idee: beachte bereits gematchten Teil



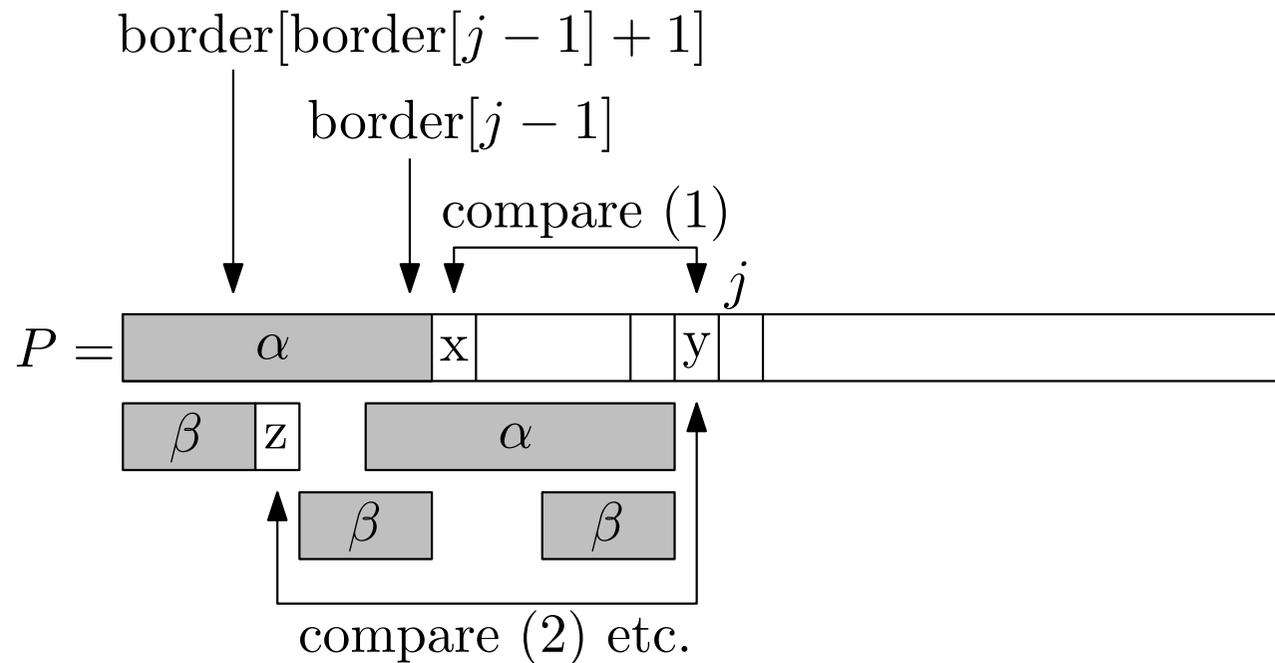
- $\text{border}[j] =$  längstes echtes Präfix von  $P_{1\dots j-1}$ , das auch (echtes) Suffix von  $P_{1\dots j-1}$  ist.  $\text{border}[1] := -1$ ,  $\text{border}[2] = 0$ .

## Knuth-Morris-Pratt (1977)

```
i := 1 // index in T
j := 1 // index in P
while  $i \leq n - m + 1$ 
    while  $j \leq m$  and  $t_{i+j-1} = p_j$  do  $j++$  // compare characters
    if  $j > m$  then
        print "P occurs at position i in T"
     $i := i + j - \text{border}[j] - 1$  // advance in T
     $j := \max\{1, \text{border}[j] + 1\}$  // skip first  $\text{border}[j]$  characters of P
```

# Berechnung des Border-Arrays

- seien die Werte bis zur Position  $j - 1$  bereits berechnet



## Berechnung des Border-Arrays

□ in  $O(m)$  Zeit:

$\text{border}[1] := -1$

$i := \text{border}[1]$  // position in  $P$

**for**  $j = 2, \dots, m + 1$

**while**  $i \geq 0$  and  $p_{i+1} \neq p_{j-1}$  **do**  $i = \text{border}[i + 1]$

$i++$

$\text{border}[j] := i$

# Volltextsuche von Langsam bis Superschnell

**Gegeben:** Text  $S$  ( $n := |S|$ ), Muster (Pattern)  $P$  ( $m := |P|$ ),  $n \gg m$

**Gesucht:** Alle/erstes/nächstes Vorkommen von  $P$  in  $S$

naiv:  $O(nm)$

$P$  vorverarbeiten:  $O(n + m)$

Mit Fehlern: ???

$S$  vorverarbeiten: Textindizes. Erstes Vorkommen:

Invertierter Index: gute heuristik

Suffix Array:  $O(m \log n) \dots O(m)$

# Invertierter Index

- 1 The old night keeper keeps the keep in the town
- 2 In the big old house in the big old gown
- 3 The house in the town had the big old keep
- 4 Where the old night keeper never did sleep
- 5 The night keeper keeps the keep in the night
- 6 And keeps in the dark and sleeps in the light

term $t$	$f_t$	Invertierte Liste für $t$
and	1	(6,2)
big	2	(2,2), (3,1)
dark	1	(6,1)
did	1	(4,1)
gown	1	(2,1)
had	1	(3,1)
house	2	(2,1), (3,1)
in	5	(1,1), (2,2), (3,1), (5,1), (6,2)
keep	3	(1,1), (3,1), (5,1)
...	...	...

# Etwas “Stringology”-Notation

Alphabet  $\Sigma$ : Menge  $\{a, b, c, \dots\}$ .

String  $S$ : Array  $S[0..n) := S[0..n - 1] := [S[0], \dots, S[n - 1]]$   
von Buchstaben aus  $\Sigma$ .

Suffix:  $S_i := S[i..n)$

Endmarkierungen:  $S[n] := S[n + 1] := \dots := 0$   
 $0$  ist kleiner als alle anderen Zeichen

$S = \text{banana} :$

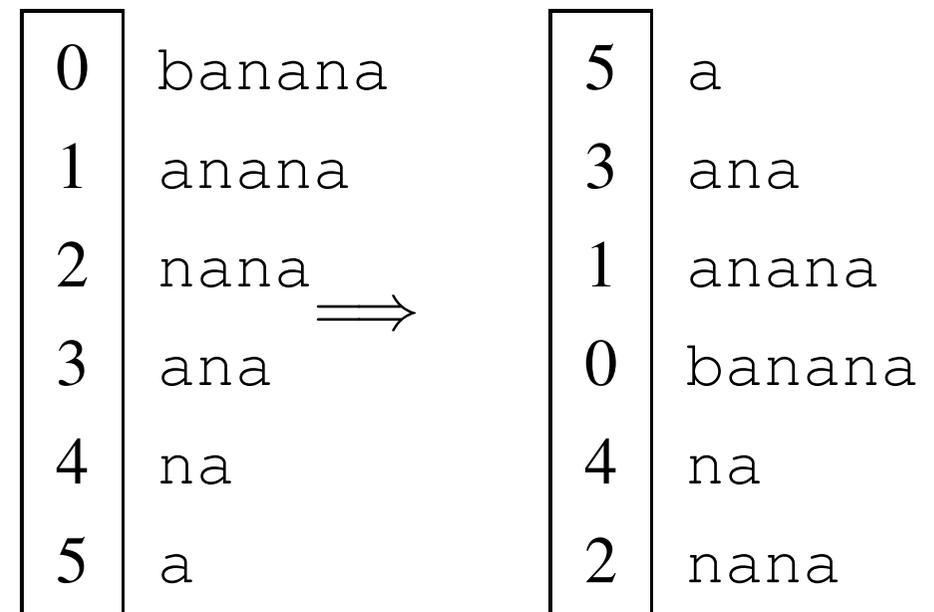
0	banana
1	anana
2	nana
3	ana
4	na
5	a

# Suffixe Sortieren

Sortiere die Menge  $\{S_0, S_1, \dots, S_{n-1}\}$   
 von Suffixen des Strings  $S$  der Länge  $n$   
 (Alphabet  $[1, n] = \{1, \dots, n\}$ )  
 in lexikographische Reihenfolge.

□ suffix  $S_i = S[i, n]$  für  $i \in [0..n - 1]$

$S = \text{banana}$ :



# Anwendungen

- Volltextsuche
- Burrows-Wheeler Transformation (`bzip2` Kompressor)
- Ersatz für kompliziertere **Suffixbäume**
- Bioinformatik: Wiederholungen suchen (in  $O(n)$  möglich?) ,...

# Volltextsuche

Suche **Muster (pattern)**  $P[0..m]$  im Text  $S[0..n]$   
mittels Suffix-Tabelle  $SA$  of  $S$ .

Binäre Suche:  $O(m \log n)$  gut für kurze Muster

Binäre Suche mit lcp:  $O(m + \log n)$  falls wir die  
**längsten gemeinsamen (common) Präfixe**  
zwischen verglichenen Zeichenketten vorberechnen

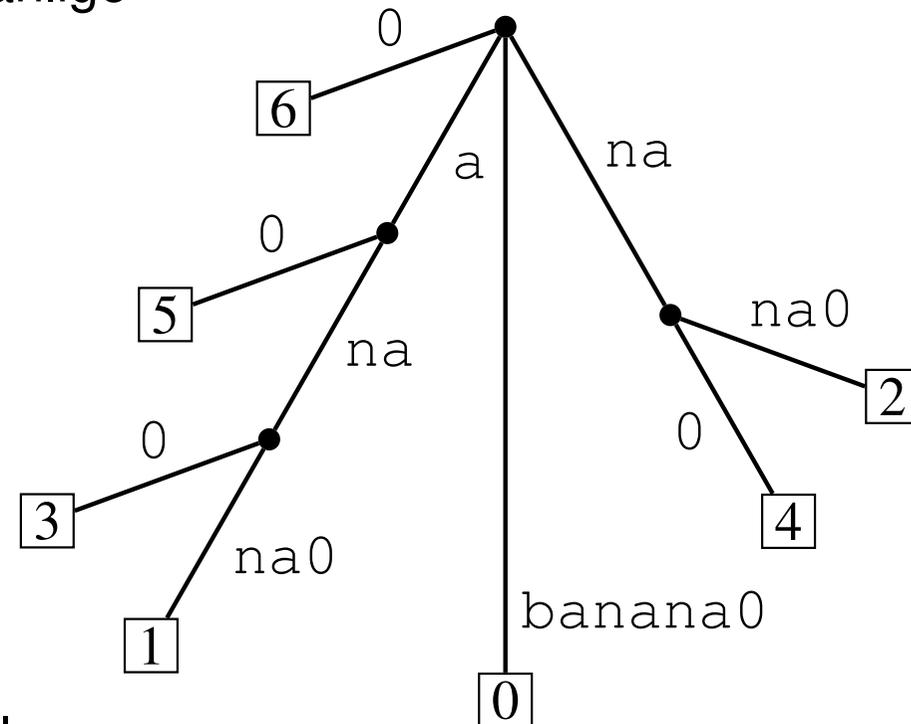
Suffix-Baum:  $O(n)$  kann aus **SA berechnet werden**

# Suffix-Baum

[Weiner '73][McCreight '76][Ukkonen '95]

- kompaktierter Trie der Suffixe
- + Zeit  $O(n)$  [Farach 97] für ganzzahlige Alphabete
- + Mächtigstes Werkzeug der Stringology?
- Hoher Platzverbrauch
- Effiziente direkte Konstruktion ist kompliziert
- kann aus SA in Zeit  $O(n)$  abgelesen werden

$S = \text{banana0}$



## Suche in Suffix-Bäumen

- Suche (alle/ein) Vorkommen von  $P_{1..m}$  in  $T$ :
- Wenn ausgehende Kanten Arrays der Größe  $|\Sigma|$ :
  - $O(m)$  Suchzeit
  - $O(n|\Sigma|)$  Gesamtplatz
- Wenn ausgehende Kanten Arrays der Größe prop. zur #Kinder:
  - $O(m \log |\Sigma|)$  Suchzeit
  - $O(n)$  Platz

# Alphabet-Modell

Geordnetes Alphabet: Zeichen können nur **verglichen** werden

Konstante Alphabetgröße: endliche Menge  
deren Größe nicht von  $n$  abhängt.

**Ganzzahliges Alphabet:** Alphabet ist  $\{1, \dots, \sigma\}$   
für eine ganze Zahl  $\sigma \geq 2$

# Geordnetes $\rightarrow$ ganzzahliges Alphabet

Sortiere die Zeichen von  $S$

Ersetze  $S[i]$  durch seinen Rang

012345      135024

banana  $\rightarrow$  aaabnn

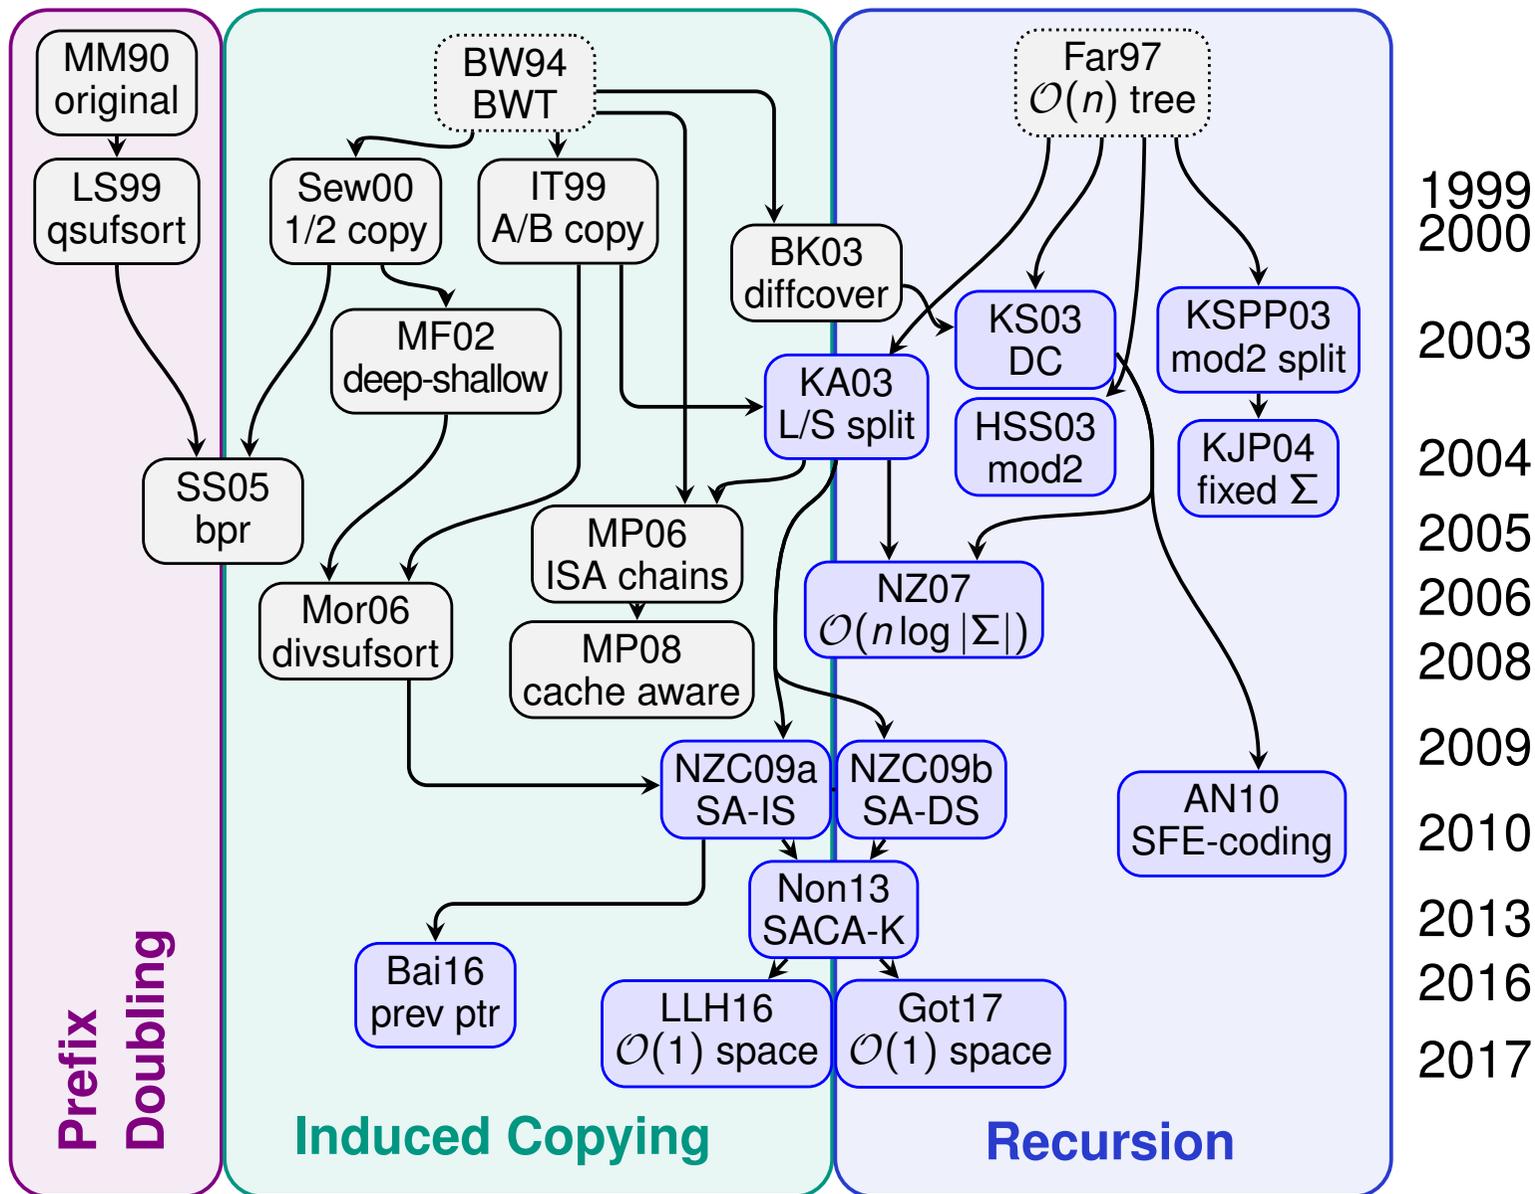
213131  $\leftarrow$  111233

## **Verallgemeinerung: Lexikographische Namen**

Sortiere die  $k$ -Tupel  $S[i..i+k)$  für  $i \in 1..n$

Ersetze  $S[i]$  durch den Rang von  $S[i..i+k)$  unter den Tupeln

# Suffix Array Konstruktionsalgorithmen



# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>0</sub> [i]	T <sub>i</sub>	ISA <sub>0</sub> [i]	L
0	0	t o b e o r n o t t o b e \$	0	-
1	1	o b e o r n o t t o b e \$	1	-
2	2	b e o r n o t t o b e \$	2	-
3	3	e o r n o t t o b e \$	3	-
4	4	o r n o t t o b e \$	4	-
5	5	r n o t t o b e \$	5	-
6	6	n o t t o b e \$	6	-
7	7	o t t o b e \$	7	-
8	8	t t o b e \$	8	-
9	9	t o b e \$	9	-
10	10	o b e \$	10	-
11	11	b e \$	11	-
12	12	e \$	12	-
13	13	\$	13	-

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>1</sub> [i]	T <sub>i</sub>	ISA <sub>1</sub> [i]	L
0	13	0 \$	11	-1
1	2	1 b e o r n o t t o b e \$	6	2
2	11	b e \$	1	-
3	3	3 e o r n o t t o b e \$	3	2
4	12	e \$	6	-
5	6	5 n o t t o b e \$	10	-1
6	1	6 o b e o r n o t t o b e \$	5	4
7	4	o r n o t t o b e \$	6	-
8	7	o t t o b e \$	11	-
9	10	o b e \$	11	-
10	5	10 r n o t t o b e \$	6	-1
11	0	11 t o b e o r n o t t o b e \$	1	3
12	8	t t o b e \$	3	-
13	9	t o b e \$	0	-

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>1</sub> [i]	T <sub>i</sub>	ISA <sub>1</sub> [i]	L
0	13	0 \$	11	-1
1	2	1 b e 3	6	2
2	11	1 b e 3	1	-
3	3	3 e o 6	3	2
4	12	3 e \$ 0	6	-
5	6	5 n o t t o b e \$	10	-1
6	1	6 o b 1	5	4
7	4	6 o r 10	6	-
8	7	6 o t 11	11	-
9	10	6 o b 1	11	-
10	5	10 r n o t t o b e \$	6	-1
11	0	11 t o 6	1	3
12	8	11 t t 11	3	-
13	9	11 t o 6	0	-

ISA[SA[i] + 1]

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>2</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 1]	ISA <sub>1</sub> [i]	L
0	13	0	\$	11	-1
1	2	1	b e 3	6	2
2	11	1	b e 3	1	-
3	12	3	e \$ 0	3	-3
4	3	3	e o 6	6	-
5	6	5	n o t t o b e \$	10	-
6	1	6	o b 1 e o r n o t t o b e \$	5	2
7	10	6	o b 1 e \$	6	-
8	4	10	o r 10 o t t o b e \$	11	-3
9	7	10	o t 11 o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	0	11	t o 6 o e o r n o t t o b e \$	1	2
12	9	11	t o 6 o e \$	3	-
13	8	11	t t 11 o b e \$	0	-1

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>2</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 1]	ISA <sub>2</sub> [i]	L
0	13	0	\$	11	-1
1	2	1	b e 3	6	2
2	11	1	b e 3	1	-
3	12	3	e \$ 0	4	-3
4	3	4	e o 6	8	-
5	6	5	n o t t o b e \$	10	-
6	1	6	o b 1	5	2
7	10	6	o b 1	9	-
8	4	8	o r 10	13	-3
9	7	9	o t 11	11	-
10	5	10	r n o t t o b e \$	6	-
11	0	11	t o 6	1	2
12	9	11	t o 6	3	-
13	8	13	t t 11	0	-1

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>2</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 2]	ISA <sub>2</sub> [i]	L
0	13	0	\$	11	-1
1	2	1	b e o r n o t t o b e \$	6	2
2	11	1	b e \$	1	-
3	12	3	e \$	4	-3
4	3	4	e o r n o t t o b e \$	8	-
5	6	5	n o t t o b e \$	10	-
6	1	6	o b e o r n o t t o b e \$	5	2
7	10	6	o b e \$	9	-
8	4	8	o r n o t t o b e \$	13	-3
9	7	9	o t t o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	0	11	t o b e o r n o t t o b e \$	1	2
12	9	11	t o b e \$	3	-
13	8	13	t t o b e \$	0	-1

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>4</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 2]	ISA <sub>2</sub> [i]	L
0	13	0	\$	11	-11
1	11	1	b e \$0	6	-
2	2	1	b e o8r n o t t o b e \$	1	-
3	12	3	e \$	4	-
4	3	4	e o r n o t t o b e \$	8	-
5	6	5	n o t t o b e \$	10	-
6	10	6	o b e3\$	5	-
7	1	6	o b e4o r n o t t o b e \$	9	-
8	4	8	o r n o t t o b e \$	13	-
9	7	9	o t t o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	0	11	t o b1e o r n o t t o b e \$	1	2
12	9	11	t o b1e \$	3	-
13	8	13	t t o b e \$	0	-1

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>4</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 2]	ISA <sub>4</sub> [i]	L
0	13	0	\$	11	-11
1	11	1	b e \$0	7	-
2	2	2	b e o8r n o t t o b e \$	2	-
3	12	3	e \$	4	-
4	3	4	e o r n o t t o b e \$	8	-
5	6	5	n o t t o b e \$	10	-
6	10	6	o b e3\$	5	-
7	1	7	o b e4o r n o t t o b e \$	9	-
8	4	8	o r n o t t o b e \$	13	-
9	7	9	o t t o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	0	11	t o b1e o r n o t t o b e \$	1	2
12	9	11	t o b1e \$	3	-
13	8	13	t t o b e \$	0	-1

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>4</sub> [i]	T <sub>i</sub>	ISA <sub>4</sub> [i]	L
0	13	0 \$	11	-11
1	11	1 b e \$	7	-
2	2	2 b e o r n o t t o b e \$	2	-
3	12	3 e \$	4	-
4	3	4 e o r n o t t o b e \$	8	-
5	6	5 n o t t o b e \$	10	-
6	10	6 o b e \$	5	-
7	1	7 o b e o r n o t t o b e \$	9	-
8	4	8 o r n o t t o b e \$	13	-
9	7	9 o t t o b e \$	11	-
10	5	10 r n o t t o b e \$	6	-
11	0	11 t o b e o r n o t t o b e \$	1	2
12	9	12 t o b e \$ 0	3	-
13	8	13 t t o b e \$	0	-1

ISA[SA[i] + 4]

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>8</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 4]	ISA <sub>4</sub> [i]	L
0	13	0	\$	11	-14
1	11	1	b e \$	7	-
2	2	2	b e o r n o t t o b e \$	2	-
3	12	3	e \$	4	-
4	3	4	e o r n o t t o b e \$	8	-
5	6	5	n o t t o b e \$	10	-
6	10	6	o b e \$	5	-
7	1	7	o b e o r n o t t o b e \$	9	-
8	4	8	o r n o t t o b e \$	13	-
9	7	9	o t t o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	9	11	t o b e \$ 0	3	-
12	0	12	t o b e o r 8 n o t t o b e \$	1	-
13	8	13	t t o b e \$	0	-

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

i	SA <sub>8</sub> [i]	T <sub>i</sub>	ISA[SA[i] + 4]	ISA <sub>8</sub> [i]	L
0	13	0	\$	12	-14
1	11	1	b e \$	7	-
2	2	2	b e o r n o t t o b e \$	2	-
3	12	3	e \$	4	-
4	3	4	e o r n o t t o b e \$	8	-
5	6	5	n o t t o b e \$	10	-
6	10	6	o b e \$	5	-
7	1	7	o b e o r n o t t o b e \$	9	-
8	4	8	o r n o t t o b e \$	13	-
9	7	9	o t t o b e \$	11	-
10	5	10	r n o t t o b e \$	6	-
11	9	11	t o b e \$ 0	3	-
12	0	12	t o b e o r 8 n o t t o b e \$	1	-
13	8	13	t t o b e \$	0	-

## SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

**Idee (aus [MM93]):** Sortiere Suffixe bis zu  $2h$  Zeichen tief mittels Informationen über die Ordnung der Suffixe bis zur Tiefe  $h$ .

**Def.:** Die  $h$ -Ordnung ist die lexikographische Ordnung bis zur Tiefe  $h$ .

**Original [MM93]:** Sortiere alle Suffix  $s_i$  mit dem Rang von  $s_i$  in einer  $h$ -Ordnung als ersten Sortier-Schlüssel und dem Rang von  $s_i + h$  als zweiten Sortier-Schlüssel. Dies ergibt eine  $2h$ -Ordnung.

**Definitionen [LS99]:** Wenn  $SA_h$  in einer  $h$ -Ordnung sind, dann

1. nennt man eine maximale Sequenz aufeinanderfolgender Suffixe in  $SA_h$  mit den gleichen  $h$  initialen Zeichen eine  $h$ -Gruppe.
2. Eine  $h$ -Gruppe der Länge eins nennt man sortiert oder Singleton, anderenfalls heißt eine Gruppe unsortiert. Eine maximale Sequenz von sortierten Gruppen heißt eine konsolidierte sortierte Gruppe.

# SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

Algorithmus [LS'99]: Präfix Verdopplung

Gegeben ist ein Text  $T$  der Länge  $n := |T|$ .

1. Enumeriere alle Suffixe in einem Array  $SA_0$  durch  $SA_0[i] = i$ .
2. Sortiere  $SA_0$  nach  $T[i]$  für Index  $i$  und erhalte  $SA_1$ . Setze  $h = 1$ .
3. Für  $i = 0, \dots, n$  setze  $ISA_1[i]$  auf den aktuellen Rang der 1-Gruppe von Suffix  $i$ . Dies ist der kleinste Index in  $SA_1[i]$  der ein Suffix mit dem gleichen ersten Buchstaben wie das Suffix  $i$ .
4. Für jede unsortierte Gruppe in  $SA_1[a..b]$  setze  $L[a]$  auf dessen Länge. Für jede konsolidierte sortierte Gruppe in  $SA_1[a..b]$ , setze  $L[a]$  auf seine negierte Länge.

## SA mit Präfix Verdopplung

[Larsson, Sadakane'99]

- Sortiere jede unsortierte Gruppe in  $SA_h$  (mit multikey quicksort), mittels  $ISA_h[SA_h[i] + h]$  als den Sortier-Schlüssel für Index  $i$ . Verwende  $L$  um die unsortierten Gruppen zu finden. Erhalte  $SA_{2h}$ .
- Betrachte Folgen gleicher Schlüssel in den eben sortierten Gruppen: markiere Singletons mit  $-1$  in  $L$  und unsortierte  $2h$ -Gruppen mit positiven Längen. Konsolidiere die negativen Sprungwerte aufeinanderfolgende sortierte Gruppen.
- Aktualisiere  $ISA_{2h}$  für alle bearbeiteten Gruppen, setze  $h := 2h$ .
- Wenn  $SA_h$  noch unsortierte Gruppen enthält ( $L[0] \neq -n$ ), goto 5.

Laufzeit:  $\mathcal{O}(n \log n)$ . Platz:  $8n (+ 1n)$ . Worst-case Eingabe:  $[a^n]$ .

# Suffixtabellen

aus

# Linear Work Suffix Array Construction

Juha Kärkkäinen, Peter Sanders, Stefan Burkhardt

Journal of the ACM

Seiten 1–19, Nummer 6, Band 53.

## Ein erster Teile-und-Herrsche-Ansatz

1.  $SA^1 = \text{sort} \{S_i : i \text{ ist ungerade}\}$  (Rekursion)
2.  $SA^0 = \text{sort} \{S_i : i \text{ ist gerade}\}$  (einfach mittels  $SA^1$ )
3. Mische  $SA^0$  und  $SA^1$  (schwierig)

Problem: wie vergleicht man gerade und ungerade Suffixe?

[Farach 97] hat einen Linearzeitalgorithmus für

Suffix-**Baum**-Konstruktion entwickelt, der auf dieser Idee beruht.

Sehr **kompliziert**.

Das war auch der einzige bekannte Algorithmus für Suffix-**Tabellen**

(läßt sich leicht aus S-Baum ablesen.)

## $SA^1$ berechnen

- Erstes Zeichen weglassen.

banana  $\rightarrow$  anana

- Ersetze Buchstabenpaare durch Ihre **lexikographischen Namen**

an	an	a0
----	----	----

 $\rightarrow$  221

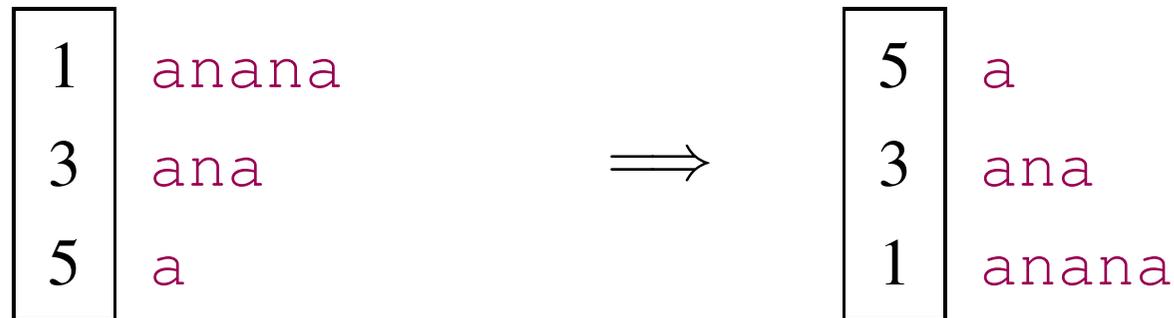
- Rekursion

$\langle 1, 21, 221 \rangle$

- Rückübersetzen

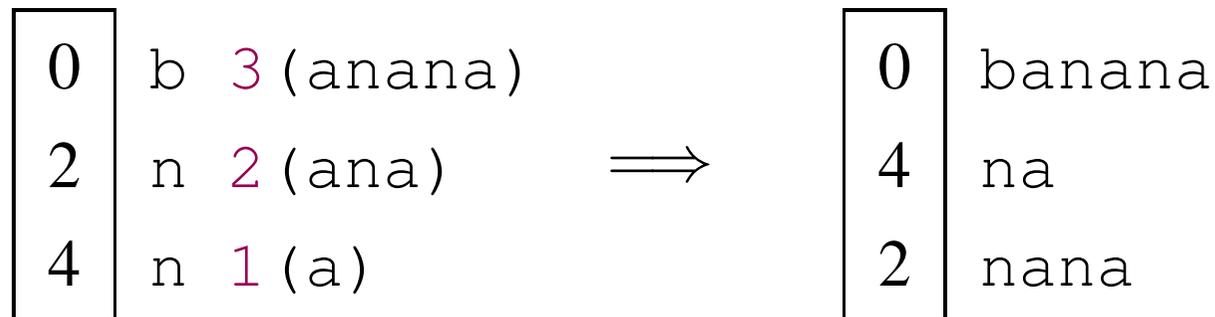
$\langle a, ana, anana \rangle$

# Berechne $SA^0$ aus $SA^1$



Ersetze  $S_i, i \bmod 2 = 0$  durch  $(S[i], r(S_{i+1}))$

mit  $r(S_{i+1}) :=$  Rang von  $S_{i+1}$  in  $SA^1$

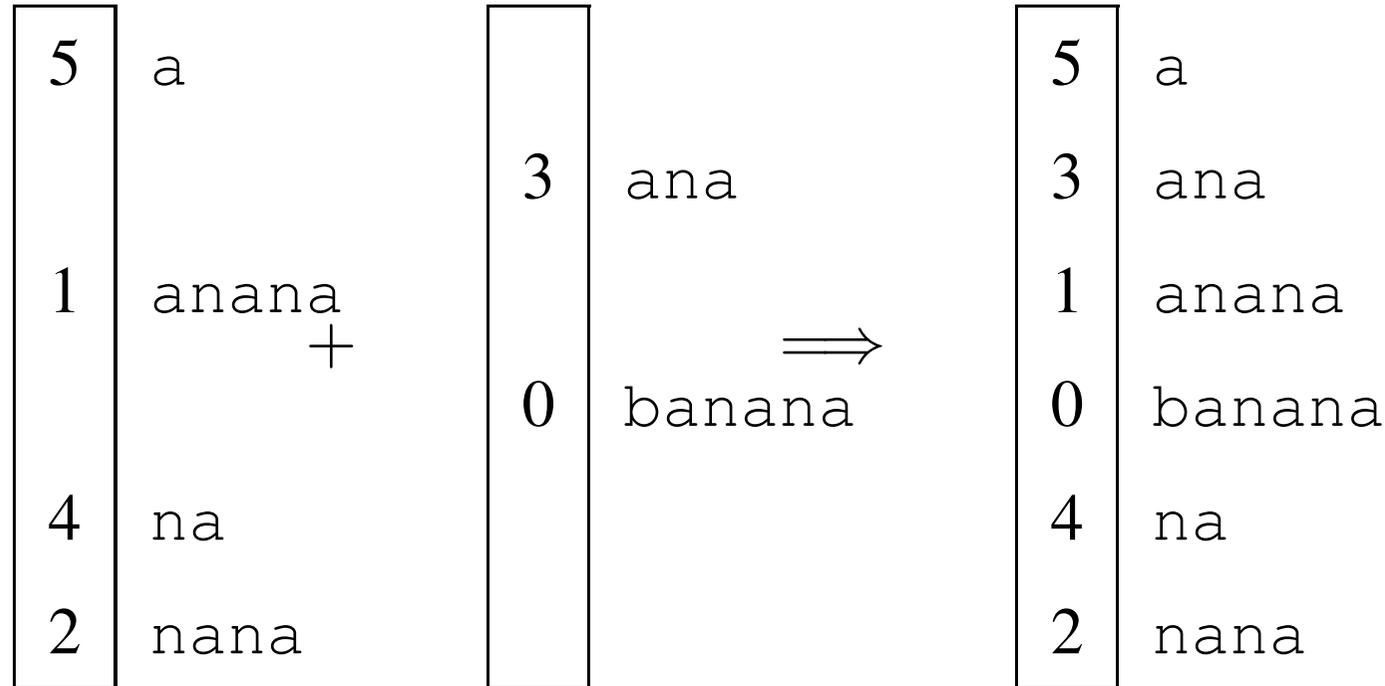


Radix-Sort

# Asymmetrisches Divide-and-Conquer

1.  $SA^{12} = \text{sort } \{S_i : i \bmod 3 \neq 0\}$  (Rekursion)
2.  $SA^0 = \text{sort } \{S_i : i \bmod 3 = 0\}$  (einfach mittels  $SA^{12}$ )
3. Mische  $SA^{12}$  und  $SA^0$  (einfach!)

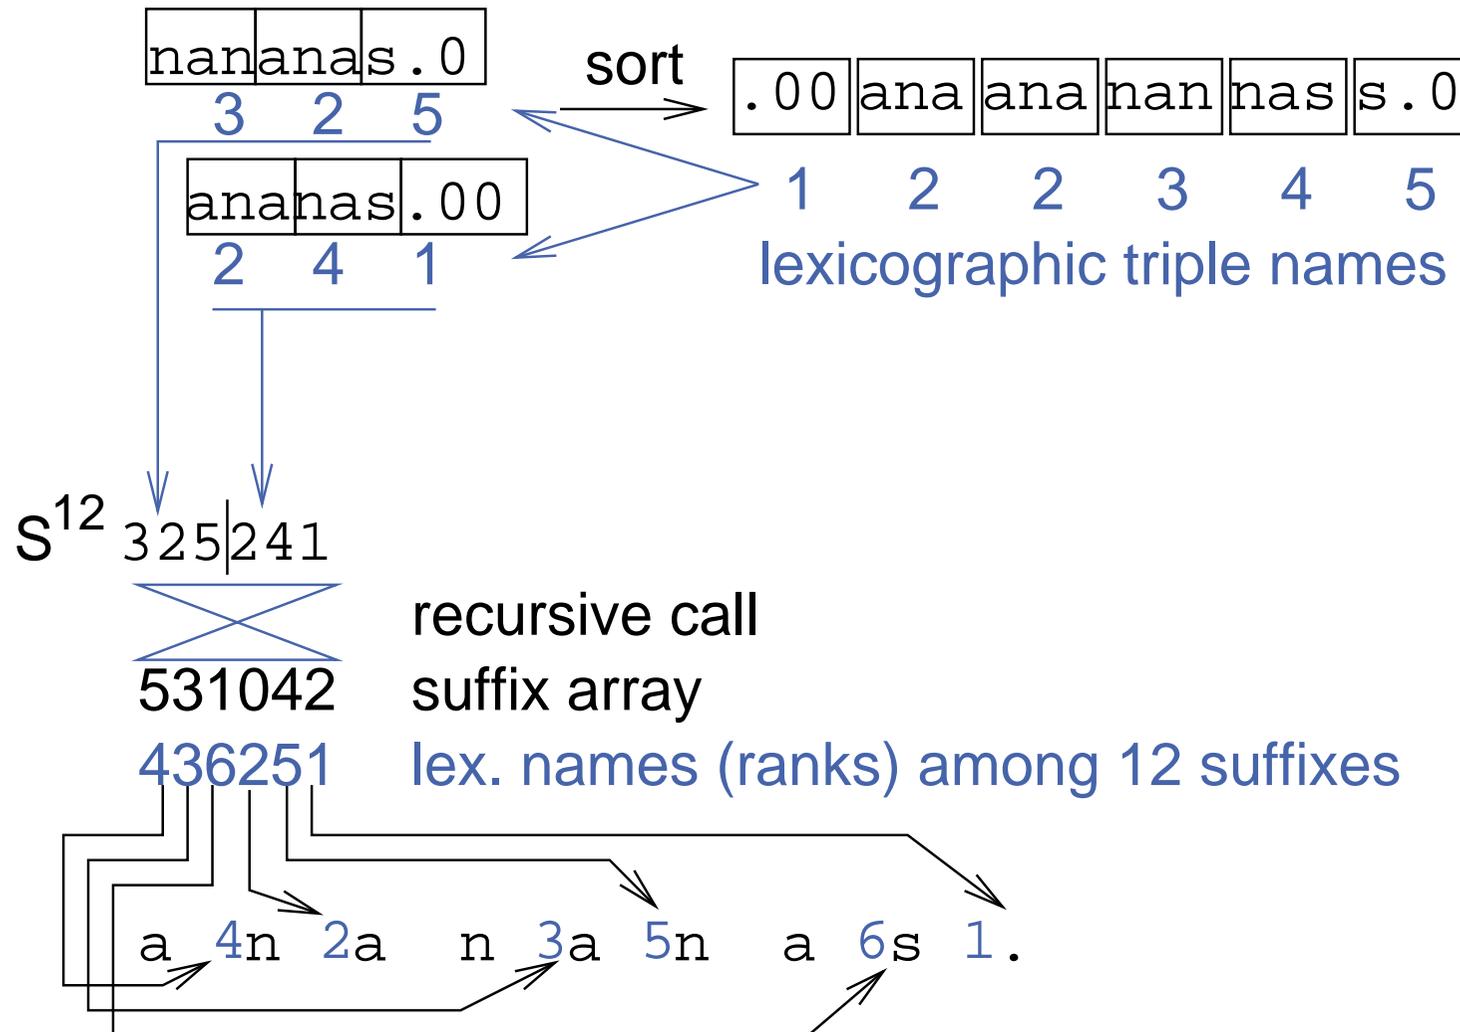
$S = \text{banana}$



# Rekursion, Beispiel

012345678

S ananas.



# Rekursion

- **sortiere Tripel**  $S[i..i+2]$  für  $i \bmod 3 \neq 0$   
(LSD Radix-Sortieren)
- Finde **lexikographische Namen**  $S'[1..2n/3]$  der Tripel,  
(d.h.,  $S'[i] < S'[j]$  gdw  $S[i..i+2] < S[j..j+2]$ )
- $S^{12} = [S'[i] : i \bmod 3 = 1] \circ [S'[i] : i \bmod 3 = 2]$ ,  
Suffix  $S_i^{12}$  von  $S^{12}$  repräsentiert  $S_{3i+1}$   
Suffix  $S_{n/3+i}^{12}$  von  $S^{12}$  repräsentiert  $S_{3i+2}$
- **Rekursion** auf  $(S^{12})$  (Alphabetgröße  $\leq 2n/3$ )
- Annotiere die 12-Suffixe mit ihrer Position in rek. Lösung

# Least Significant Digit First Radix Sort

Hier: Sortiere  $n$  3-Tupel von ganzen Zahlen  $\in [0..n]$  in  
**lexikographische** Reihenfolge

Sortiere nach 3. Position

Elemente sind nach Pos. 3 sortiert

Sortiere **stabil** nach 2. Position

Elemente sind nach Pos. 2,3 sortiert

Sortiere **stabil** nach 1. Position

Elemente sind nach Pos. 1,2,3 sortiert

# Stabiles Ganzzahliges Sortieren

Sortiere  $a[0..n)$  nach  $b[0..n)$  mit  $\text{key}(a[i]) \in [0..n]$

$c[0..n] := [0, \dots, 0]$

for  $i \in [0..n)$  do  $c[a[i]]++$

$s := 0$

for  $i \in [0..n)$  do  $(s, c[i]) := (s + c[i], s)$

for  $i \in [0..n)$  do  $b[c[a[i]]++] := a[i]$

Zähler

zähle

Präfixsummen

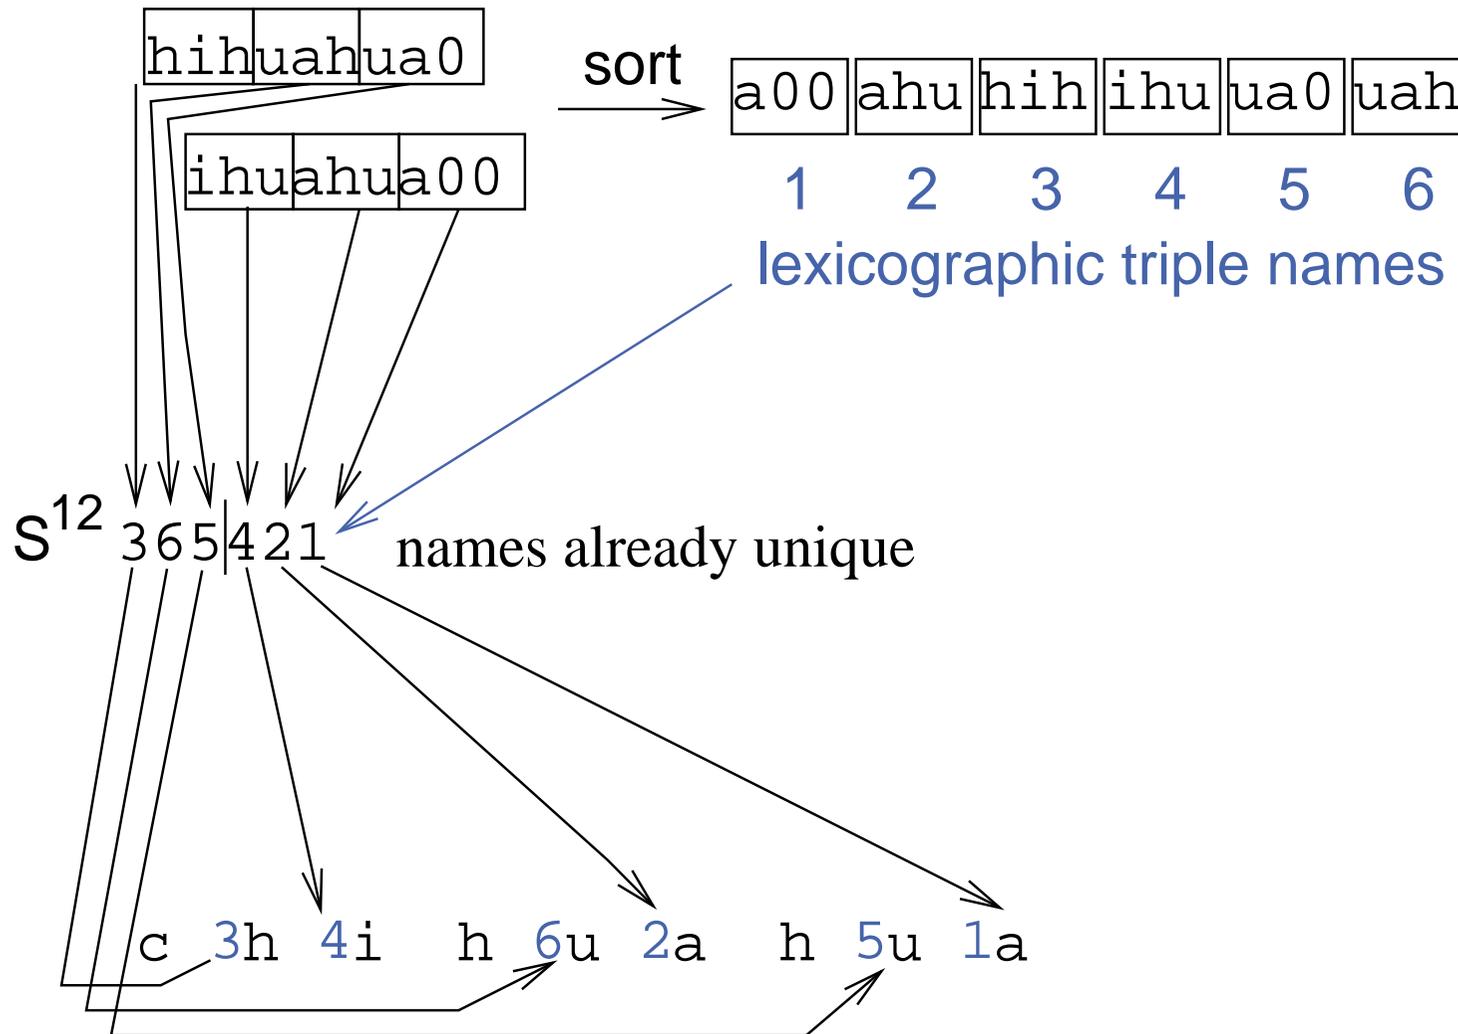
bucket sort

Zeit  $O(n)$  !

# Rekursions-Beispiel: Einfacher Fall

012345678

S chihuahua



## Sortieren der mod 0 Suffixe

0	c	3	(h	4	i	h	6	u	2	a	h	5	u	1	a)
1															
2															
3	h	6	(u	2	a	h	5	u	1	a)					
4															
5															
6	h	5	(u	1	a)										
7															
8															

Benutze Radix-Sort (LSD-Reihenfolge bereits bekannt)

# Mische $SA^{12}$ und $SA^0$

$0 < 1 \Leftrightarrow c_n < c_n$	4:	$(6) u \ 2$ (ahua)
$0 < 2 \Leftrightarrow cc_n < cc_n$	7:	$(5) u \ 1$ (a)
3: h $6$ u $2$ (ahua)	2:	$(4) i \ h \ 6$ (uahua)
6: h $5$ u $1$ (a)	1:	$(3) h \ 4$ (ihuahua)
0: c $3$ h $4$ (ihuahua)	5:	$(2) a \ h \ 5$ (ua)
	8:	$(1) a \ 0 \ 0 \ 0$ (0)

⇓

- 8: a
- 5: ahua
- 0: chihuahua
- 1: hihuahua
- 6: hua
- 3: huahua
- 2: ihuahua
- 7: ua
- 4: uahua

# Analyse

1. Rekursion:  $T(2n/3)$  plus

Tripel extrahieren:  $O(n)$  (forall  $i, i \bmod 3 \neq 0$  do ...)

Tripel sortieren:  $O(n)$

(e.g., LSD-first radix sort — 3 Durchgänge)

Lexikographisches benennen:  $O(n)$  (scan)

Rekursive Instanz konstruieren:  $O(n)$  (forall names do ...)

2.  $SA^0$  =sortiere  $\{S_i : i \bmod 3 = 0\}$ :  $O(n)$

(1 Radix-Sort Durchgang)

3. mische  $SA^{12}$  and  $SA^0$ :  $O(n)$

(gewöhnliches Mischen mit merkwürdiger Vergleichsfunktion)

Insgesamt:  $T(n) \leq cn + T(2n/3)$

$\Rightarrow T(n) \leq 3cn = O(n)$

# Implementierung: Vergleichs-Operatoren

```
inline bool leq(int a1, int a2,    int b1, int b2) {  
    return(a1 < b1 || a1 == b1 && a2 <= b2);  
}  
inline bool leq(int a1, int a2, int a3,    int b1, int b2, int b3) {  
    return(a1 < b1 || a1 == b1 && leq(a2,a3, b2,b3));  
}
```

# Implementierung: Radix-Sortieren

```
// stably sort a[0..n-1] to b[0..n-1] with keys in 0..K from r
static void radixPass(int* a, int* b, int* r, int n, int K)
{ // count occurrences
  int* c = new int[K + 1]; // counter array
  for (int i = 0; i <= K; i++) c[i] = 0; // reset counters
  for (int i = 0; i < n; i++) c[r[a[i]]]++; // count occurrences
  for (int i = 0, sum = 0; i <= K; i++) { // exclusive prefix sums
    int t = c[i]; c[i] = sum; sum += t;
  }
  for (int i = 0; i < n; i++) b[c[r[a[i]]]++] = a[i]; // sort
  delete [] c;
}
```

# Implementierung: Tripel Sortieren

```
void suffixArray(int* s, int* SA, int n, int K) {
    int n0=(n+2)/3, n1=(n+1)/3, n2=n/3, n02=n0+n2;
    int* s12 = new int[n02 + 3]; s12[n02]= s12[n02+1]= s12[n02+2]=0;
    int* SA12 = new int[n02 + 3]; SA12[n02]=SA12[n02+1]=SA12[n02+2]=0;
    int* s0 = new int[n0];
    int* SA0 = new int[n0];

    // generate positions of mod 1 and mod 2 suffixes
    // the "+(n0-n1)" adds a dummy mod 1 suffix if n%3 == 1
    for (int i=0, j=0; i < n+(n0-n1); i++) if (i%3 != 0) s12[j++] = i;

    // lsb radix sort the mod 1 and mod 2 triples
    radixPass(s12 , SA12, s+2, n02, K);
    radixPass(SA12, s12 , s+1, n02, K);
    radixPass(s12 , SA12, s , n02, K);
}
```

# Implementierung: Lexikographisches Benennen

```
// find lexicographic names of triples
int name = 0, c0 = -1, c1 = -1, c2 = -1;
for (int i = 0; i < n02; i++) {
    if (s[SA12[i]] != c0 || s[SA12[i]+1] != c1 || s[SA12[i]+2] != c2) {
        name++; c0 = s[SA12[i]]; c1 = s[SA12[i]+1]; c2 = s[SA12[i]+2];
    }
    if (SA12[i] % 3 == 1) { s12[SA12[i]/3] = name; } // left half
    else { s12[SA12[i]/3 + n0] = name; } // right half
}
```

# Implementierung: Rekursion

```
// recurse if names are not yet unique
if (name < n02) {
    suffixArray(s12, SA12, n02, name);
    // store unique names in s12 using the suffix array
    for (int i = 0; i < n02; i++) s12[SA12[i]] = i + 1;
} else // generate the suffix array of s12 directly
    for (int i = 0; i < n02; i++) SA12[s12[i] - 1] = i;
```

## Implementierung: Sortieren der mod 0 Suffixe

```
for (int i=0, j=0; i < n02; i++)  
    if (SA12[i] < n0) s0[j++] = 3*SA12[i];  
radixPass(s0, SA0, s, n0, K);
```

# Implementierung: Mischen

```
for (int p=0, t=n0-n1, k=0; k < n; k++) {
#define GetI() (SA12[t] < n0 ? SA12[t] * 3 + 1 : (SA12[t] - n0) * 3 + 2)
    int i = GetI(); // pos of current offset 12 suffix
    int j = SA0[p]; // pos of current offset 0 suffix
    if (SA12[t] < n0 ?
        leq(s[i], s12[SA12[t] + n0], s[j], s12[j/3]) :
        leq(s[i],s[i+1],s12[SA12[t]-n0+1], s[j],s[j+1],s12[j/3+n0]))
    { // suffix from SA12 is smaller
        SA[k] = i; t++;
        if (t == n02) { // done --- only SA0 suffixes left
            for (k++; p < n0; p++, k++) SA[k] = SA0[p];
        }
    } else {
        SA[k] = j; p++;
        if (p == n0) { // done --- only SA12 suffixes left
            for (k++; t < n02; t++, k++) SA[k] = GetI();
        }
    }
}
delete [] s12; delete [] SA12; delete [] SA0; delete [] s0; }
```

# Verallgemeinerung: Differenzenüberdeckungen

Ein **Differenzenüberdeckung**  $D$  modulo  $v$  ist eine Teilmenge von  $[0, v)$ ,  
so dass  $\forall i \in [0, v) : \exists j, k \in D : i \equiv k - j \pmod{v}$ .

Beispiel:

$\{1, 2\}$  ist eine Differenzenüberdeckung modulo 3.

$\{1, 2, 4\}$  ist eine Differenzenüberdeckung modulo 7.

- Führt zu platzeffizienterer Variante
- Schneller für kleine Alphabete

## Verbesserungen / Verallgemeinerungen

- tuning
  - größere Differenzenüberdeckungen
  - Kombiniere mit den besten Alg. für einfache Eingaben
- [Manzini Ferragina 02, Schürmann Stoye 05, Yuta Mori 08]

# Suffixtabellenkonstruktion: Zusammenfassung

- einfache, direkte, Linearzeit für Suffixtabellenkonstruktion
- einfach anpassbar auf fortgeschrittene Berechnungsmodelle
- Verallgemeinerung auf Diff-Überdeckungen ergibt platzeffiziente Implementierung

## Suche in Suffix Arrays

Given:  $T$ ,  $SA$ ,  $P$ .

$l := 1; r := n + 1$

**while**  $l < r$  **do** //search left index

$q := \lfloor \frac{l+r}{2} \rfloor$

**if**  $P >_{\text{lex}} T_{SA[q] \dots \min\{SA[q]+m-1, n\}}$

**then**  $l := q + 1$  **else**  $r := q$

$s := l; l--; r := n$

**while**  $l < r$  **do** //search right index

$q := \lceil \frac{l+r}{2} \rceil$

**if**  $P =_{\text{lex}} T_{SA[q] \dots \min\{SA[q]+m-1, n\}}$

**then**  $l := q$  **else**  $r := q - 1$

**return**  $[s, l]$

□ Zeit  $O(m \log n)$  (geht auch:  $O(m + \log n)$ )

# LCP-Array

speichert Längen der **längsten gemeinsamen Präfixe** lexikographisch benachbarter Suffixe!

$S = \text{banana}$ :

0	banana
1	anana
2	nana
3	ana
4	na
5	a

SA =

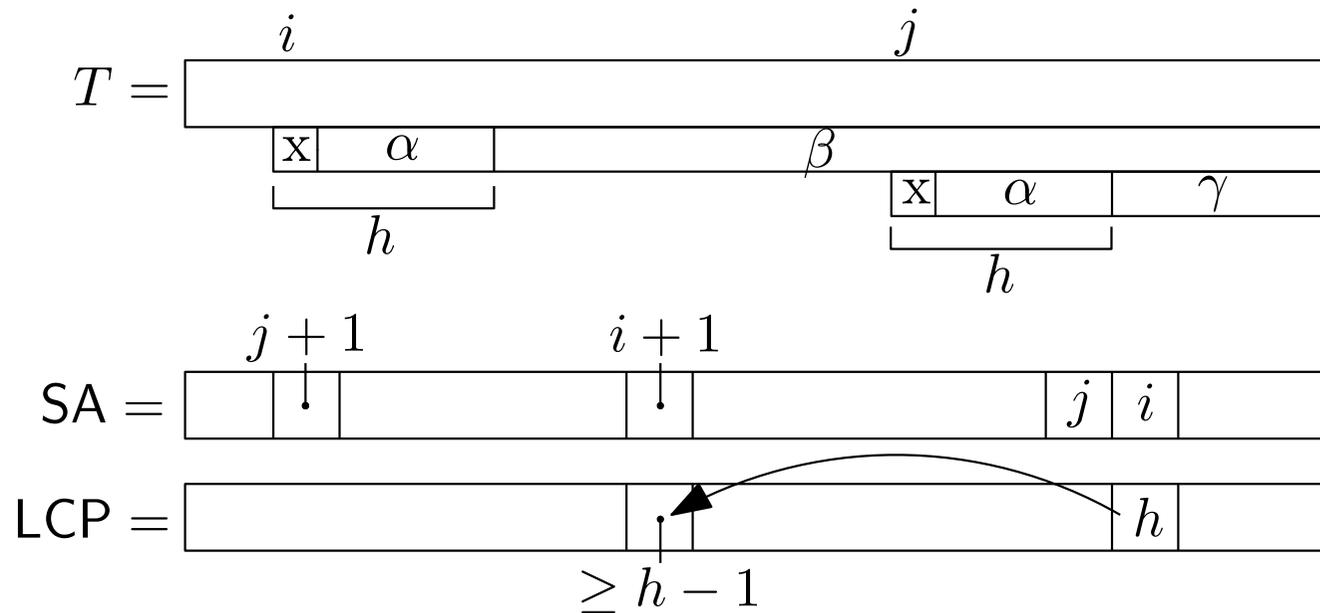
5	a
3	ana
1	anana
0	banana
4	na
2	nana

LCP =

⊥	a
1	<b>a</b> na
3	<b>ana</b> na
0	banana
0	na
2	<b>na</b> na

# LCP-Array: Berechnung

- **naiv**  $O(n^2)$
- inverses Suffix-Array:  $SA^{-1}[SA[i]] = i$  (wo steht  $i$  in SA?)
- For all  $1 \leq i < n$ :  $LCP[SA^{-1}[i+1]] \geq LCP[SA^{-1}[i]] - 1$ .



## LCP-Array: Berechnung

□ For all  $1 \leq i < n$ :  $\text{LCP}[\text{SA}^{-1}[i+1]] \geq \text{LCP}[\text{SA}^{-1}[i]] - 1$ .

$h := 0, \text{LCP}[1] := 0$

**for**  $i = 1, \dots, n$  **do**

**if**  $\text{SA}^{-1}[i] \neq 1$  **then**

**while**  $t_{i+h} = t_{\text{SA}[\text{SA}^{-1}[i]-1]+h}$  **do**  $h++$

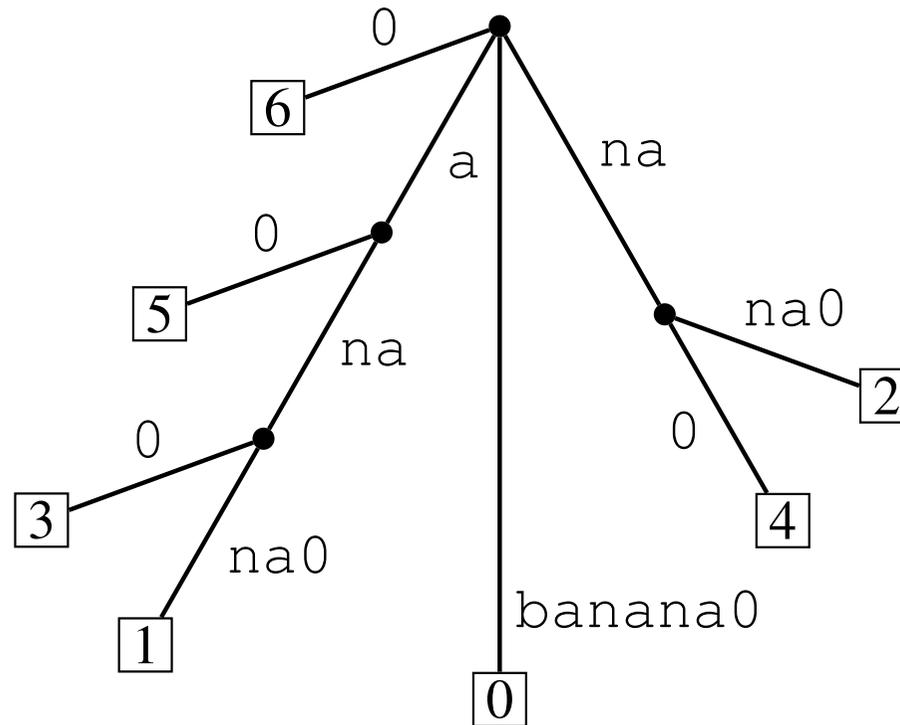
$\text{LCP}[\text{SA}^{-1}[i]] := h$

$h := \max(0, h - 1)$

□ Zeit:  $O(n)$

# Suffix-Baum aus SA und LCP

$S = \text{banana0}$



□ naiv:  $O(n^2)$

□ mit Suffix-Array: in **lexikographischer Reihenfolge**

# Suffix-Baum aus SA und LCP

- LCP-Werte helfen!
- Betrachte nur **rechtesten Pfad!**
- Finde tiefsten Knoten mit String-Tiefe  $\leq \text{LCP}[i] \rightsquigarrow$  **Einfügepunkt!**

	0	1	2	3	4	5	6
SA =	6	5	3	1	0	4	2
LCP =	0	0	1	3	0	0	2

- Zeit  $O(n)$

# Datenkompression

Problem: bei naiver Speicherung verbrauchen Daten sehr viel **Speicherplatz / Kommunikationsbandbreite**. Das läßt sich oft reduzieren.

## Varianten:

- Verlustbehaftet (mp3, jpg, ...) / **Verlustfrei** (Text, Dateien, Suchmaschinen, Datenbanken, medizin. Bildverarbeitung, Profifotografie, ...)
- 1D** (text, Zahlenfolgen,...) / 2D (Bilder) / 3D (Filme)
- nur Speicherung** / mit Operationen ( $\rightsquigarrow$  succinct data structures)

# Verlustfreie Textkompression

**Gegeben:** Alphabet  $\Sigma$

String  $S = \langle s_1, \dots, s_n \rangle \in \Sigma^*$

Textkompressionsalgorithmus  $f : S \rightarrow f(S)$  mit  $|f(S)|$  (z.B. gemessen in bits) möglichst klein.

# Theorie Verlustfreier Textkompression

Informationstheorie. Zum Beispiel

**Entropie:**  $H(S) = \sum_{c \in \Sigma} p(c) \log(1/p(c))$  wobei

$p(c) = |\{s_i : s_i = c\}|/n$  die relative Häufigkeit von  $c$  ist.

untere Schranke für **# bits** pro Zeichen falls Text einer Zufallsquelle entspränge.

↪ Huffman-Coding ist annähernd optimal! (Entropiecodierung) ????

Schon eher:

**Entropie höherer Ordnung** betrachte Teilstrings fester Länge

“Ultimativ”: Kolmogorov Komplexität. Leider nicht berechenbar.

# Theorie Verlustfreier Textkompression

**Entropie höherer Ordnung:** Gegeben ein Text  $S$  der Länge  $n$  über dem Alphabet  $\Sigma$ . Wir definieren  $N(\omega, S)$  als Konkatenation aller Zeichen, die in  $S$  auf Vorkommen von  $\omega \in \Sigma^k$  folgen. Wir definieren die **empirische Entropie der Ordnung  $k$**  wie folgt:

$$H_k(S) = \sum_{\omega \in \Sigma^k} \frac{|N(\omega, S)|}{n} H(N(\omega, S))$$

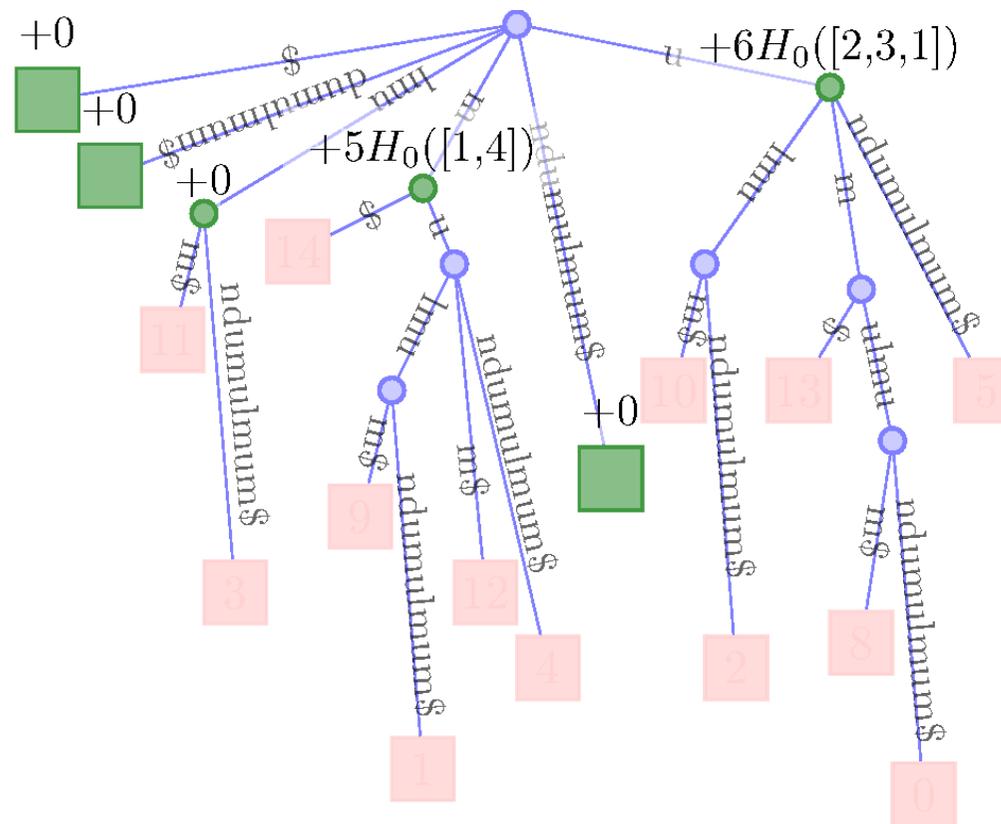
Beispiel:  $S = \text{ananas}$ ,  $k = 2$

$N(\text{an}, S) = \text{aa}$ ,  $N(\text{na}, S) = \text{ns}$ ,  $N(\text{as}, S) = \varepsilon$ .

$H_2(\text{ananas}) = \frac{2}{6} H(\text{ns}) = \frac{1}{3}$  bits

# Theorie Verlustfreier Textkompression

$H_k$ : Berechnung mittels Suffixbaumes (Beispiel:  $H_1$ )



# Theorie Verlustfreier Textkompression

Werte der empirischen Entropie in der Praxis

$H_k(S)$  in bits und (# eindeutiger Kontexte/ $|S|$  in Prozent)

$k$	dblp.xml		DNA		english		proteins	
	bits	prozent	bits	prozent	bits	prozent	bits	prozent
0	5.26	0.0	1.97	0.0	4.53	0.0	4.20	0.0
1	3.48	0.0	1.93	0.0	3.62	0.0	4.18	0.0
2	2.17	0.0	1.92	0.0	2.95	0.0	4.16	0.0
3	1.43	0.1	1.92	0.0	2.42	0.0	4.07	0.0
4	1.05	0.4	1.91	0.0	2.06	0.3	3.83	0.1
5	0.82	1.3	1.90	0.0	1.84	1.0	3.16	1.7
6	0.70	2.7	1.88	0.0	1.67	2.7	1.50	17.4

# Wörterbuchbasierte Textkompression

Grundidee: wähle  $\Sigma' \subseteq \Sigma^*$  und ersetze  $S \in \Sigma^*$  durch  $S' = \langle s'_1, \dots, s'_k \rangle \in \Sigma'^*$ , so dass  $S = s'_1 \cdot s'_2 \cdots s'_k$ . (mit  $\cdot$  = Zeichenkettenkonkatenation).

Platz  $n \lceil \log \Sigma \rceil \rightarrow k \lceil \log \Sigma' \rceil$  mit Entropiecodierung der Zeichen aus  $\Sigma'$  sogar  $k \text{Entropie}(S')$

**Problem:** zusätzlicher Platz für Wörterbuch.

OK für sehr große Datenbestände.

# Wörterbuchbasierte Textkompression – Beispiel

Volltextsuchmaschinen verwenden oft  $\Sigma' :=$  durch Leerzeichen (etc.)

separierte Wörter der zugrundeliegenden natürlichen Sprache.

Spezialbehandlung von Trennzeichen etc.

Gallia est omnis divisa in partes tres, ...

→ 

gallia	est	omnis	divisa	in	partes	tres	...
--------	-----	-------	--------	----	--------	------	-----

# Lempel-Ziv Kompression (LZ)

Idee: baue Wörterbuch “on the fly” bei Codierung und Decodierung.

Ohne explizite Speicherung!

## Naive Lempel-Ziv Kompression (LZ)

**Procedure** naiveLZCompress( $\langle s_1, \dots, s_n \rangle, \Sigma$ )

$D := \Sigma$  // Init Dictionary

$p := s_1$  // current string

**for**  $i := 2$  **to**  $n$  **do**

**if**  $p \cdot s_i \in D$  **then**  $p := p \cdot s_i$

**else**

        output code for  $p$

$D := D \cup p \cdot s_i$

$p := s_i$

output code for  $p$

## Naive LZ Dekompression

**Procedure** naiveLZDecode( $\langle c_1, \dots, c_k \rangle$ )

$D := \Sigma$

output decode( $c_1$ )

**for**  $i := 2$  **to**  $k$  **do**

**if**  $c_i \in D$  **then**

$D := D \cup \text{decode}(c_{i-1}) \cdot \text{decode}(c_i)[1]$

**else** // where  $s[1]$  is the first letter.

$D := D \cup \text{decode}(c_{i-1}) \cdot \text{decode}(c_{i-1})[1]$

output decode( $c_i$ )

# LZ Beispiel: abracadabra

#	$p$	output	input	$DU =$
1	$\perp$	-	a	a,b,c,d,r
2	a	a	b	ab
3	b	b	r	br
4	r	r	a	ra
5	a	a	c	ac
6	c	c	a	ca
7	a	a	d	ad
8	d	d	a	da
9	a	-	b	-
10	ab	ab	r	abr
11	r	-	a	-
-	ra	ra	-	-

## LZ-Verfeinerungen

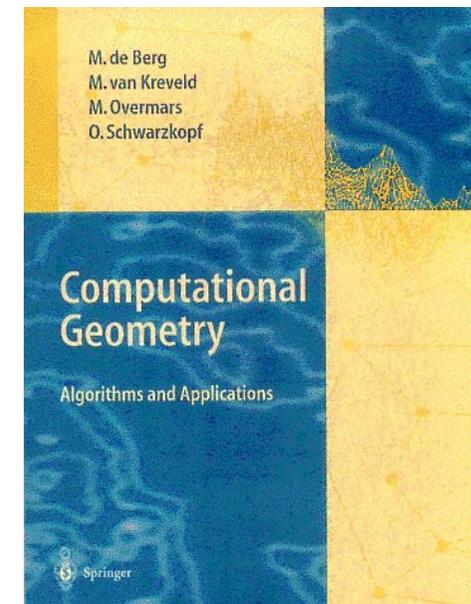
- Wörterbuchgröße begrenzen, z.B.  $|D| \leq 4096 \rightsquigarrow$  12bit codes.
- Von vorn wenn Wörterbuch voll  $\rightsquigarrow$  Blockweise arbeiten
- Kodierung mit **variabler Zahl Bits** (z.B. Huffman, arithmetic coding)
- Selten benutzte Wörterbucheinträge löschen ???
- Wörterbuch effizient implementieren:  
(universelles) hashing
- verwendet in zip/gzip mit Huffman Kodierung

# 12 Geometrische Algorithmen

- Womit beschäftigen sich geom. Algorithmen?
- Schnitt von Strecken: Bentley-Ottmann-Algorithmus
- Konvexe Hüllen
- Kleinste einschließende Kugel
- Range Search

Quelle:

[Computational Geometry – Algorithms and Applications  
de Berg, van Kreveld, Overmars, Schwartzkopf  
Springer, 1997]

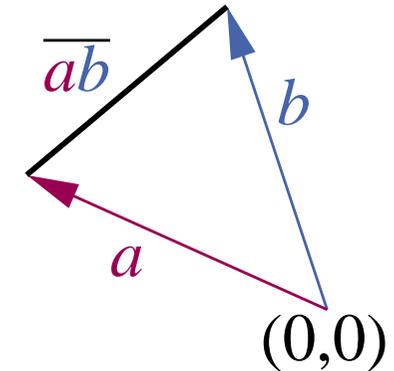


# Elementare geometrische Objekte

Punkte:  $x \in \mathbb{R}^d$

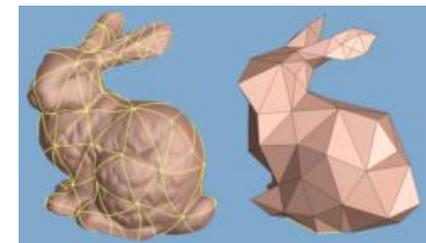
Strecken:  $\overline{ab} := \{\alpha a + (1 - \alpha)b : \alpha \in [0, 1]\}$

uvam: Halbräume, Ebenen, Kurven,...



## Dimension $d$ :

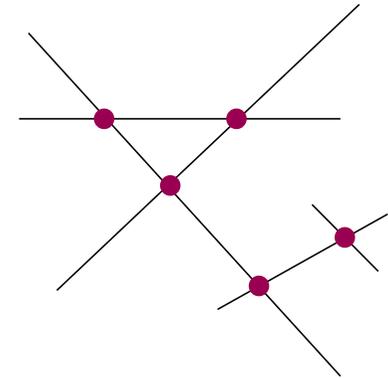
- 1: Oft trivial. Gilt i. allg. nicht als geometrisches Problem
- 2: Geogr. Informationssysteme (GIS), Bildverarbeitung,...
- 3: Computergrafik, Simulationen,...
- $\geq 4$ : Optimierung, Datenbanken, maschinelles Lernen, ...  
**curse of dimensionality!**



$n$ : Anzahl vorliegender Objekte

# Typische Fragestellungen

- Schnittpunkte zwischen  $n$  Strecken



# Typische Fragestellungen

Schnittpunkte zwischen  $n$  Strecken

Konvexe Hülle

Triangulation von Punktmenge

(2D, verallgemeinerbar)

z.B. **Delaunaytriangulierung**:

Kein Dreieck enthält weiteren Punkt

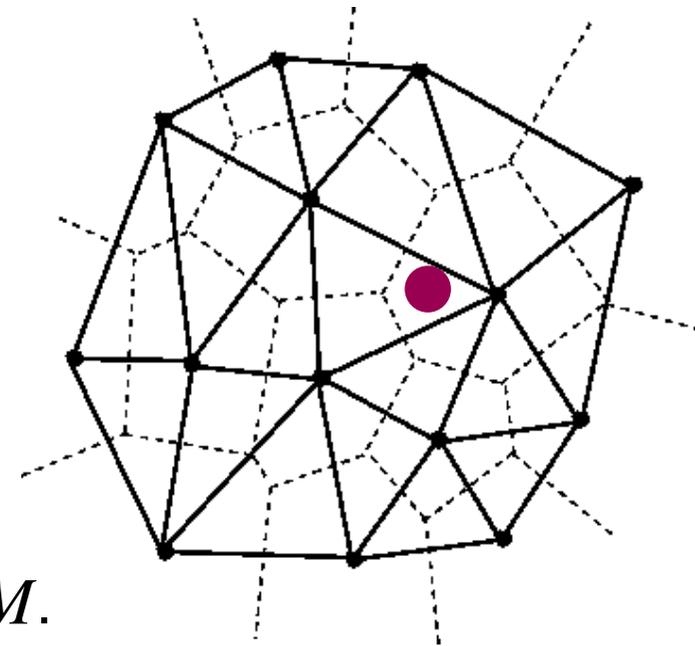
**Voronoi-Diagramme**: Sei  $x \in M \subseteq \mathbb{R}^d$ .

$\forall y \in \mathbb{R}^d$  bestimme nächstes Element aus  $M$ .

(Unterteilung von  $M$  in  $n$  **Voronozellen**)

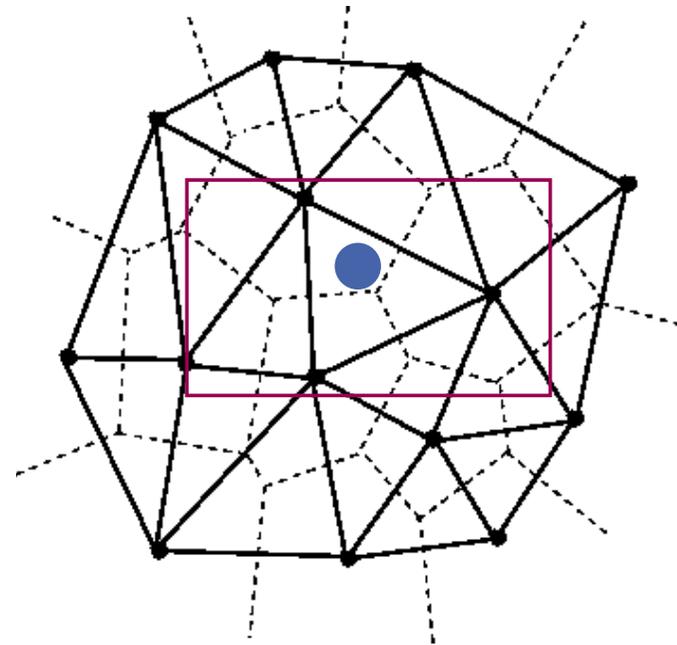
**Punktolokalisierung**: Geg. Unterteilung von  $\mathbb{R}^d$ ,  $x \in \mathbb{R}^d$ :

in welchem Teil liegt  $x$  ?



# Datenstrukturen für Punktmengen

- nächsten Nachbarn berechnen
- Bereichsanfragen
- ...



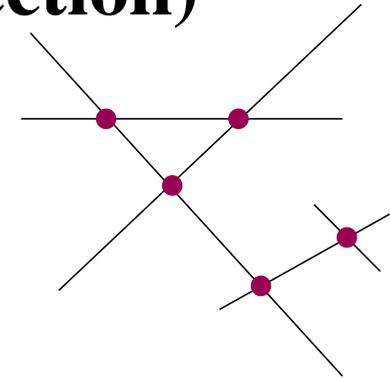
# Mehr Fragestellungen

- Sichtbarkeitsberechnungen
- Lineare Programmierung
- Geometrische Versionen von Optimierungsproblemen
  - Kürzeste Wege, z.B.  
energieeffiziente Kommunikation in Radionetzwerken
  - minimale Spannbäume  
reduzierbar auf Delaunay-Triangulierung + Graphalgorithmus
  - Matchings
  - Handlungsreisendenproblem
  - ...
- ...

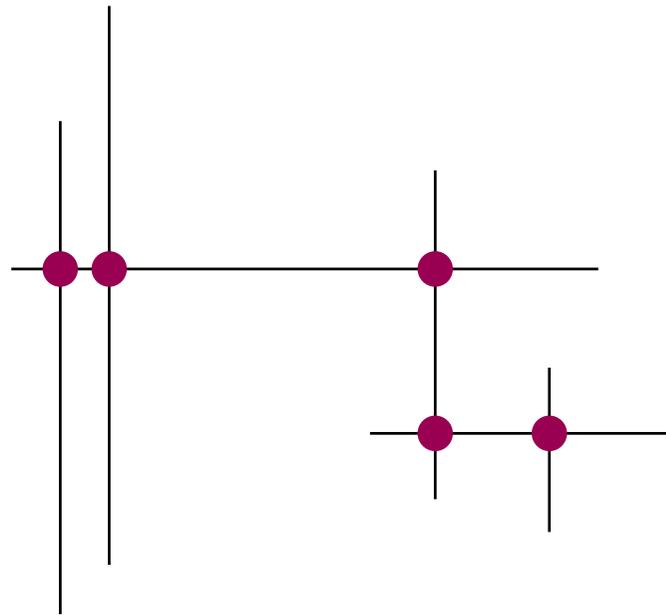
## 12.1 Streckenschnitt (line segment intersection)

**Gegeben:**  $S = \{s_1, \dots, s_n\}$ ,  $n$  Strecken

**Gesucht:** Schnittpunkte  $\bigcup_{s,t \in S} s \cap t$

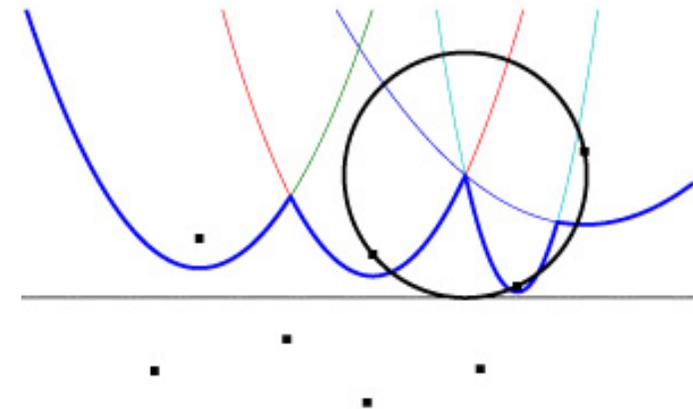


Zum Warmwerden: **Orthogonaler Streckenschnitt** – die Strecken sind parallel zur x- oder y-Achse



## Streckenschnitt: Anwendungen

- Schaltungsentwurf: wo kreuzen sich Leiterbahnen?
- GIS: Strassenkreuzungen, Brücken,...
- Erweiterungen: z.B. Graphen benachbarter Strecken/Flächen aufbauen/verarbeiten
- Noch allgemeiner:  
Plane-Sweep-Algorithmen  
für andere Fragestellungen  
(z.B. Konstruktion von  
konvexen Hüllen oder  
Voronoidiagrammen)

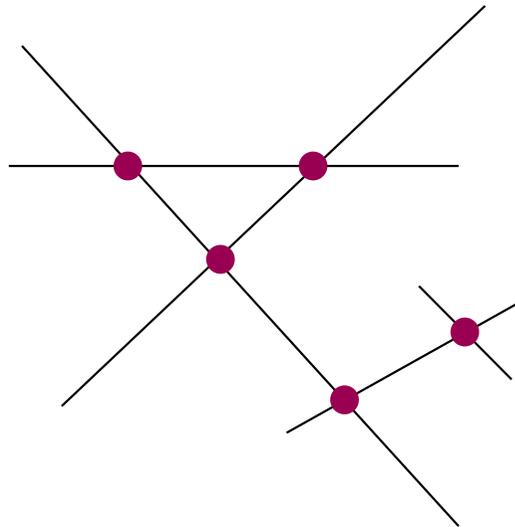


# Streckenschnitt: Naiver Algorithmus

```
foreach  $\{s, t\} \subseteq S$  do  
  if  $s \cap t \neq \emptyset$  then  
    output  $\{s, t\}$ 
```

Problem: Laufzeit  $\Theta(n^2)$ .

Zu langsam für große Datenmengen

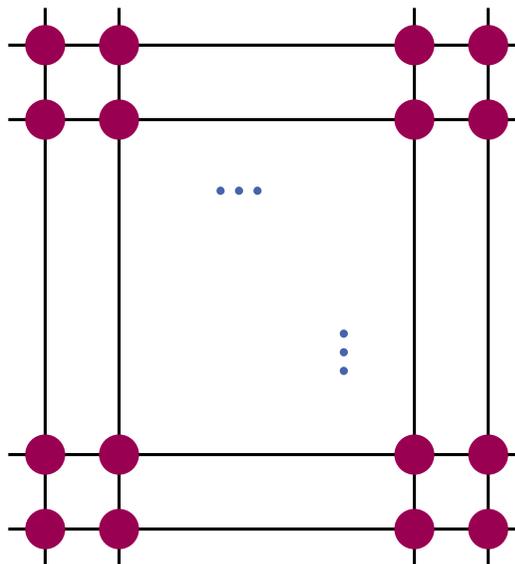


## Streckenschnitt: Untere Schranke

$\Omega(n + k)$  mit  $k :=$  Anzahl ausgegebener Schnitte.

Vergleichsbasiert:  $\Omega(n \log n + k)$  (Beweis: nicht hier)

Beobachtung  $k = \Theta(n^2)$  ist möglich, aber reale Eingaben haben meist  $k = O(n)$ .

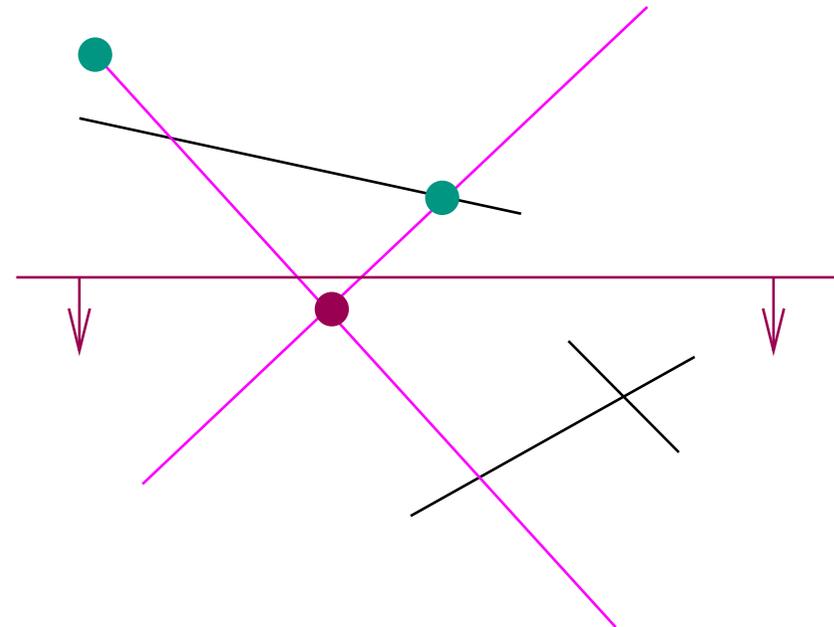


# Idee: Plane-Sweep-Algorithmen

(Waagerechte) **Sweep-Line**  $\ell$  läuft von oben nach unten.

**Invariante:** Schnittpunkte oberhalb von  $\ell$  wurden korrekt ausgegeben.

**Ansatz:** speichere jeweils Segmente, die  $\ell$  schneiden und finde deren Schnittpunkte.



## Plane-Sweep für orth. Streckenschnitt

Erstmal nur: Schnitte zwischen vertikalen und horizontalen Strecken.

$T = \langle \rangle$  : SortedSequence **of** Segment // e.g.,  $(a, b)$ -tree

**invariant**  $T$  stores the vertical segments intersecting  $\ell$

$Q := \text{sort}(\langle (y, s) : \exists \text{hor. seg. } s \text{ at } y \text{ or } \exists \text{vert. seg. } s \text{ starting/ending at } y \rangle)$

//tie breaking: vert. starting events first, vert. finishing events last

**foreach**  $(y, s) \in Q$  in descending order **do**

**if**  $s$  is a vertical segment and **starts** at  $y$  **then**  $T.\text{insert}(s)$

**else if**  $s$  is a vertical segment and **ends** at  $y$  **then**  $T.\text{remove}(s)$

**else** //we have a horizontal segment  $s = \overline{(x_1, y)(x_2, y)}$

**foreach**  $t = \overline{(x, y_1)(x, y_2)} \in T$  with  $x \in [x_1, x_2]$  **do**

output  $\{s, t\}$

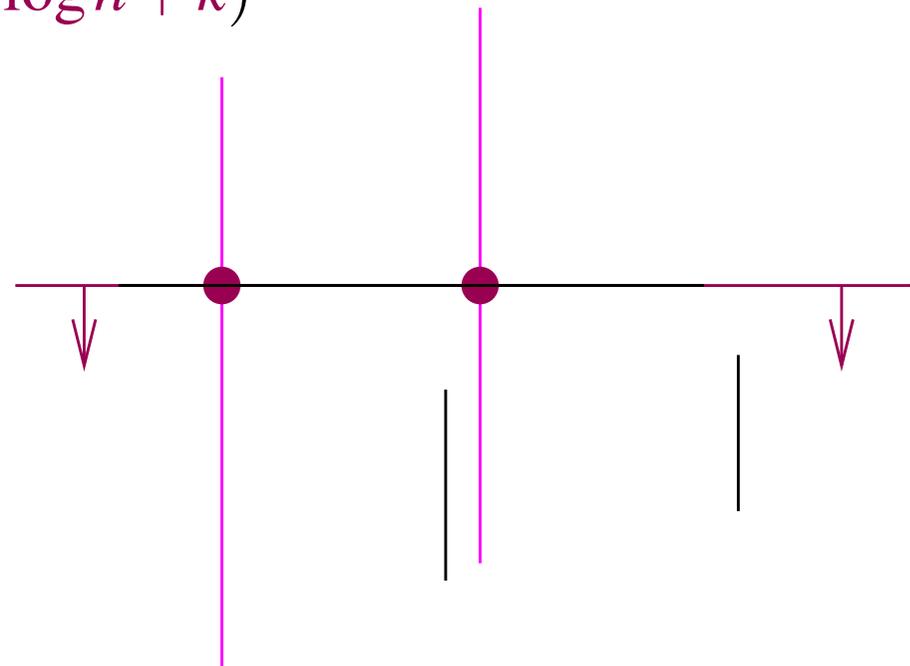
# Analyse orth. Streckenschnitt

insert:  $O(\log n)$  ( $\leq n \times$ )

remove:  $O(\log n)$  ( $\leq n \times$ )

rangeQuery:  $O(\log n + k_s)$ ,  $k_s$  Schnitte mit hor. Segment  $s$

Insgesamt:  $O(n \log n + \sum_s k_s) = O(n \log n + k)$



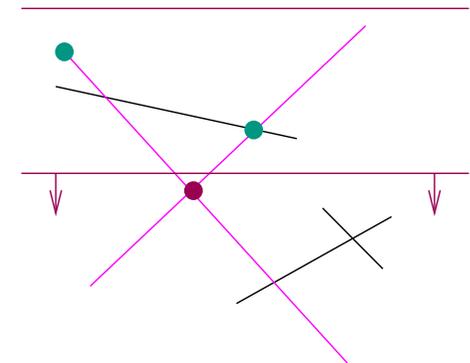
# Verallgemeinerung – aber erstmal “nicht ganz”

Annahme zunächst:

Allgemeine Lage, d.h. hier

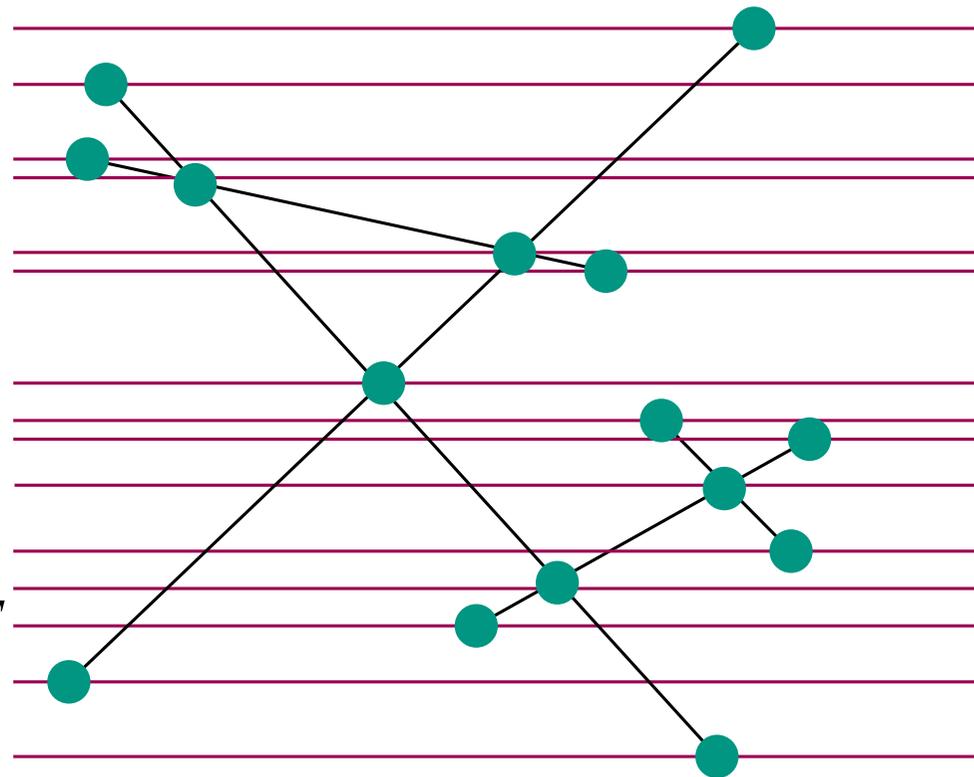
- Keine horizontalen Strecken
- Keine Überlappungen
- Schnittpunkte jeweils im Inneren von genau zwei Strecken

**Beobachtung:** kleine zuf. **Perturbationen** produzieren allg. Lage.



# Verallgemeinerung – Grundidee

- Plane-Sweep mit Sweep-Line  $\ell$
- Status  $T$  := nach  $x$  geordnete Folge der  $\ell$  schneidenden Strecken
- Ereignis := Statusänderung
  - Startpunkte
  - Endpunkte
  - Schnittpunkte
- Schnitttest nur für Segmente, die an einem Ereignispunkt in  $T$  benachbart sind.





# Verallgemeinerung – Implementierung

$T = \langle \rangle$  : SortedSequence **of** Segment

**invariant**  $T$  stores the relative order of the segments intersecting  $\ell$

$Q$  : MaxPriorityQueue

$Q := Q \cup \left\{ (\max\{y, y'\}, \text{start}, s) : s = \overline{(x, y)(x', y')} \in S \right\} // O(n \log n)$

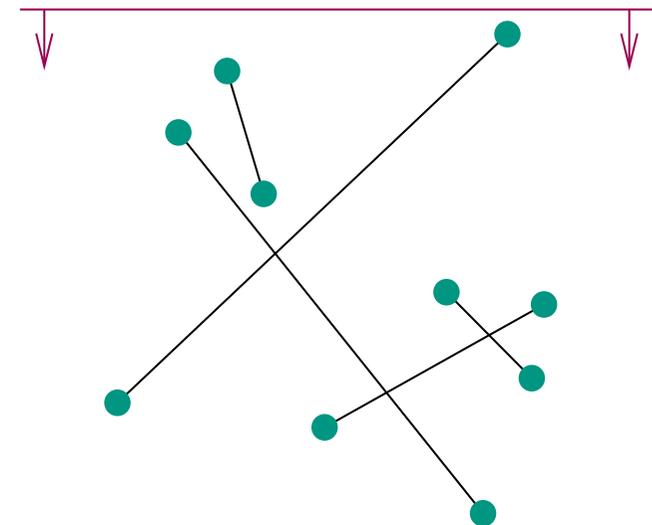
$Q := Q \cup \left\{ (\min\{y, y'\}, \text{finish}, s) : s = \overline{(x, y)(x', y')} \in S \right\} // O(n \log n)$

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

$(y, \text{type}, s) := Q.\text{deleteMax}$

$// O((n + k) \log n)$

handleEvent( $y, \text{type}, s, T, Q$ )



handleEvent( $y$ ,  $s$ ,  $T$ ,  $Q$ )

$h := T.insert(s)$

$prev := pred(h)$

$next := succ(h)$

findNewEvent( $prev$ ,  $h$ )

findNewEvent( $h$ ,  $next$ )

//  $n \times$

//  $O(\log n)$

//  $O(1)$

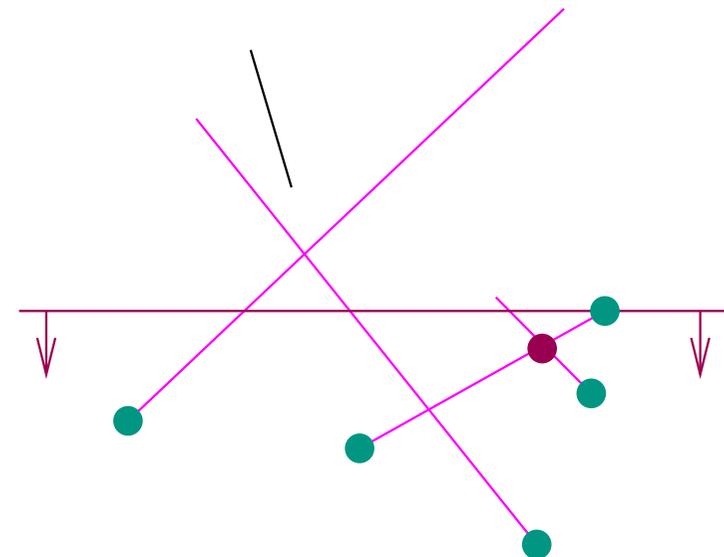
//  $O(1)$

**Procedure** findNewEvent( $s$ ,  $t$ )

**if**  $s$  and  $t$  intersect at  $y' < y$  **then**

$Q.insert((y', intersection, (s, t)))$

//  $O(1 + \log n)$



handleEvent( $y$ , finish,  $s$ ,  $T$ ,  $Q$ )

$h := T.locate(s)$

prev := pred( $h$ )

next := succ( $h$ )

$T.remove(s)$

findNewEvent(prev, next)

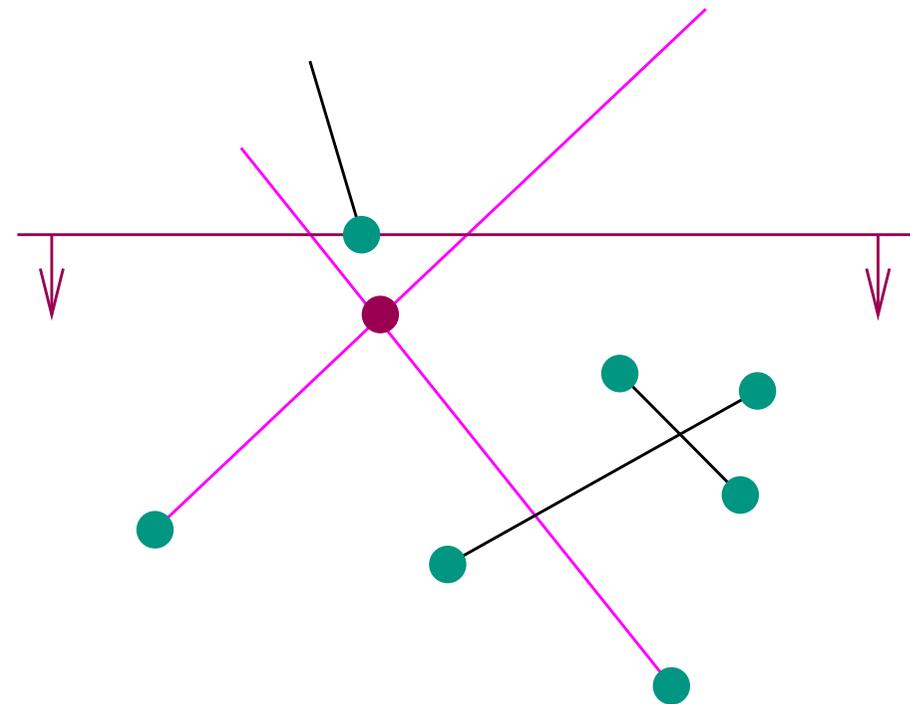
//  $n \times$

//  $O(\log n)$

//  $O(1)$

//  $O(1)$

//  $O(\log n)$



handleEvent( $y$ , intersection,  $(a, b)$ ,  $T$ ,  $Q$ )

output  $(*s \cap *t)$

$T.swap(a, b)$

prev := pred( $b$ )

next := succ( $a$ )

findNewEvent(prev,  $b$ )

findNewEvent( $a$ , next)

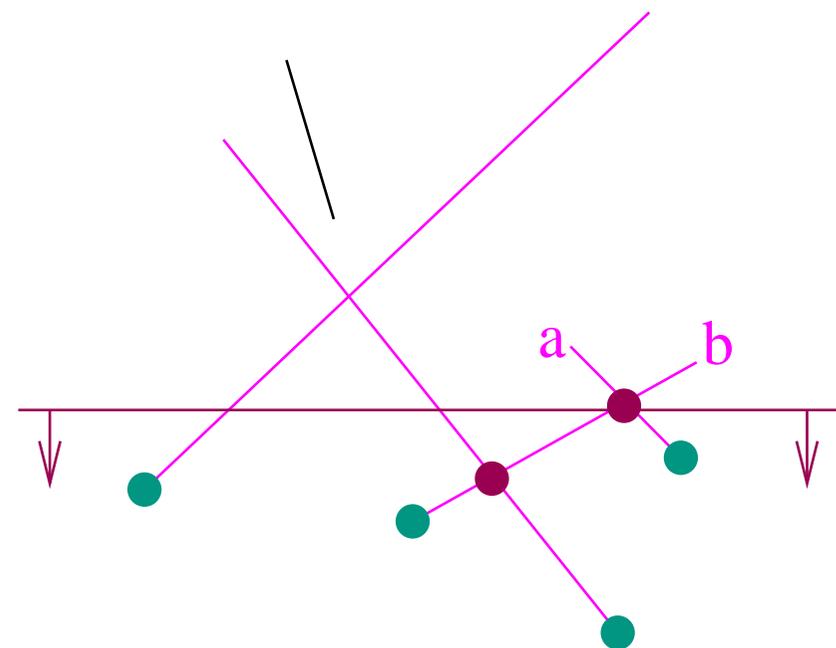
//  $k \times$

//  $O(1)$

//  $O(\log n)$

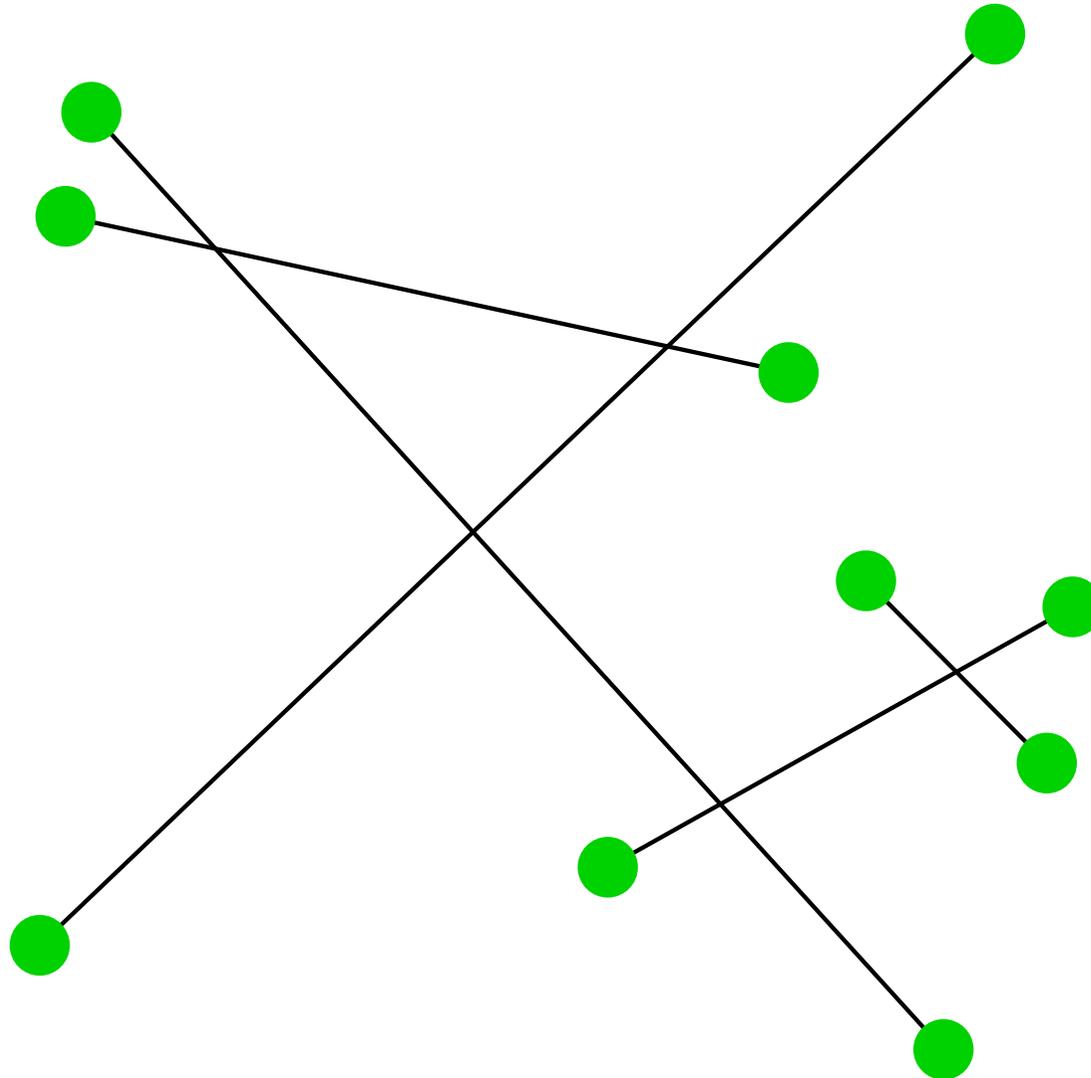
//  $O(1)$

//  $O(1)$

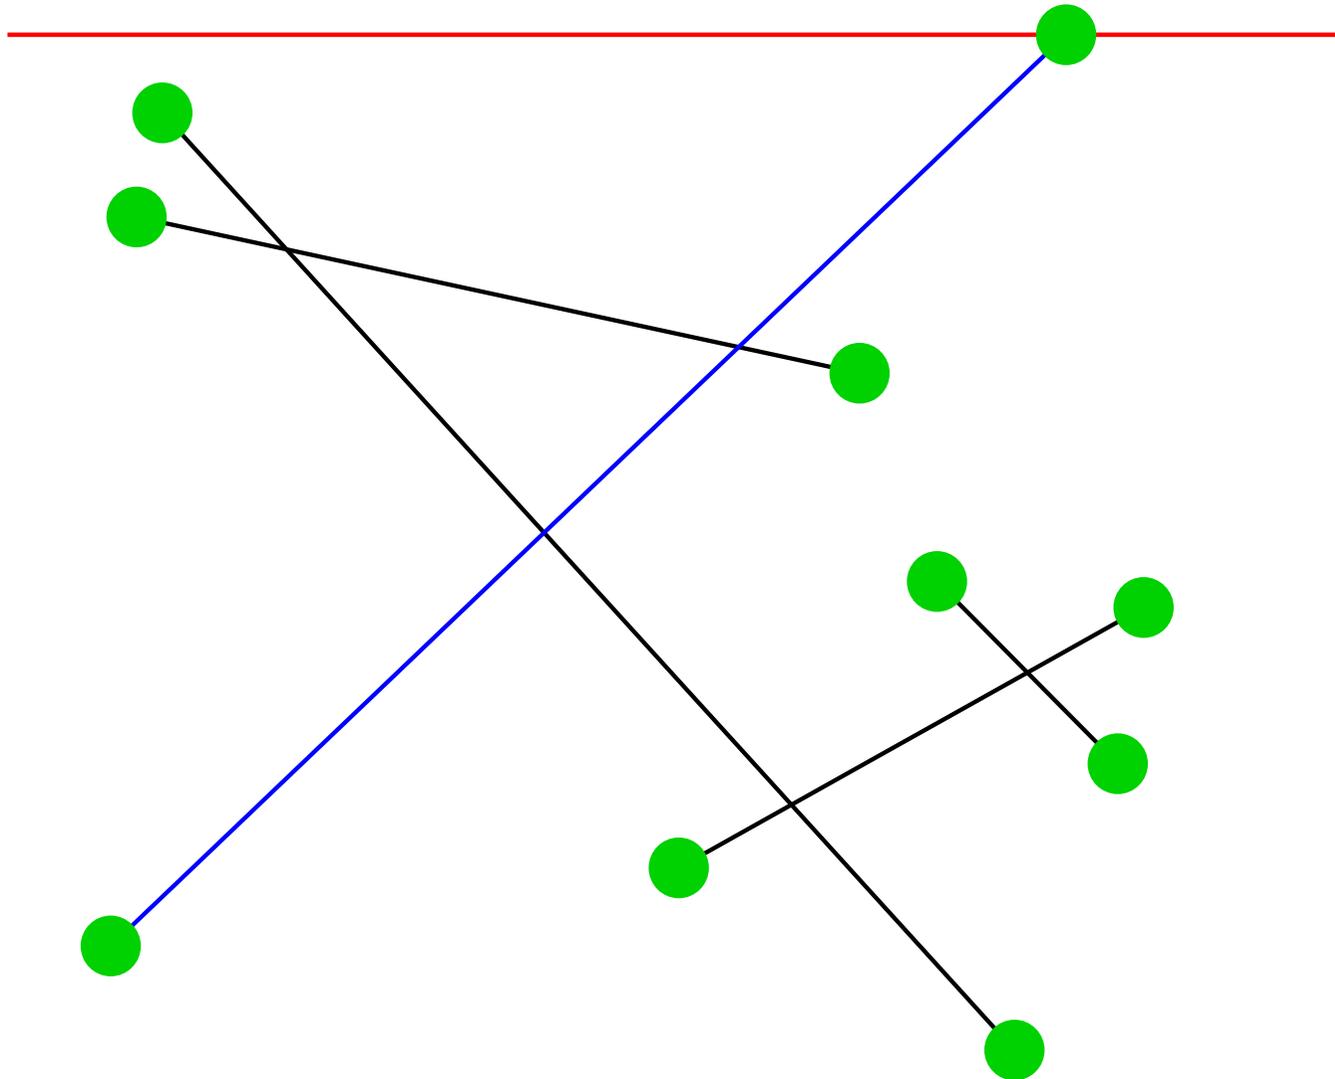


# Verallgemeinerung – Beispiel

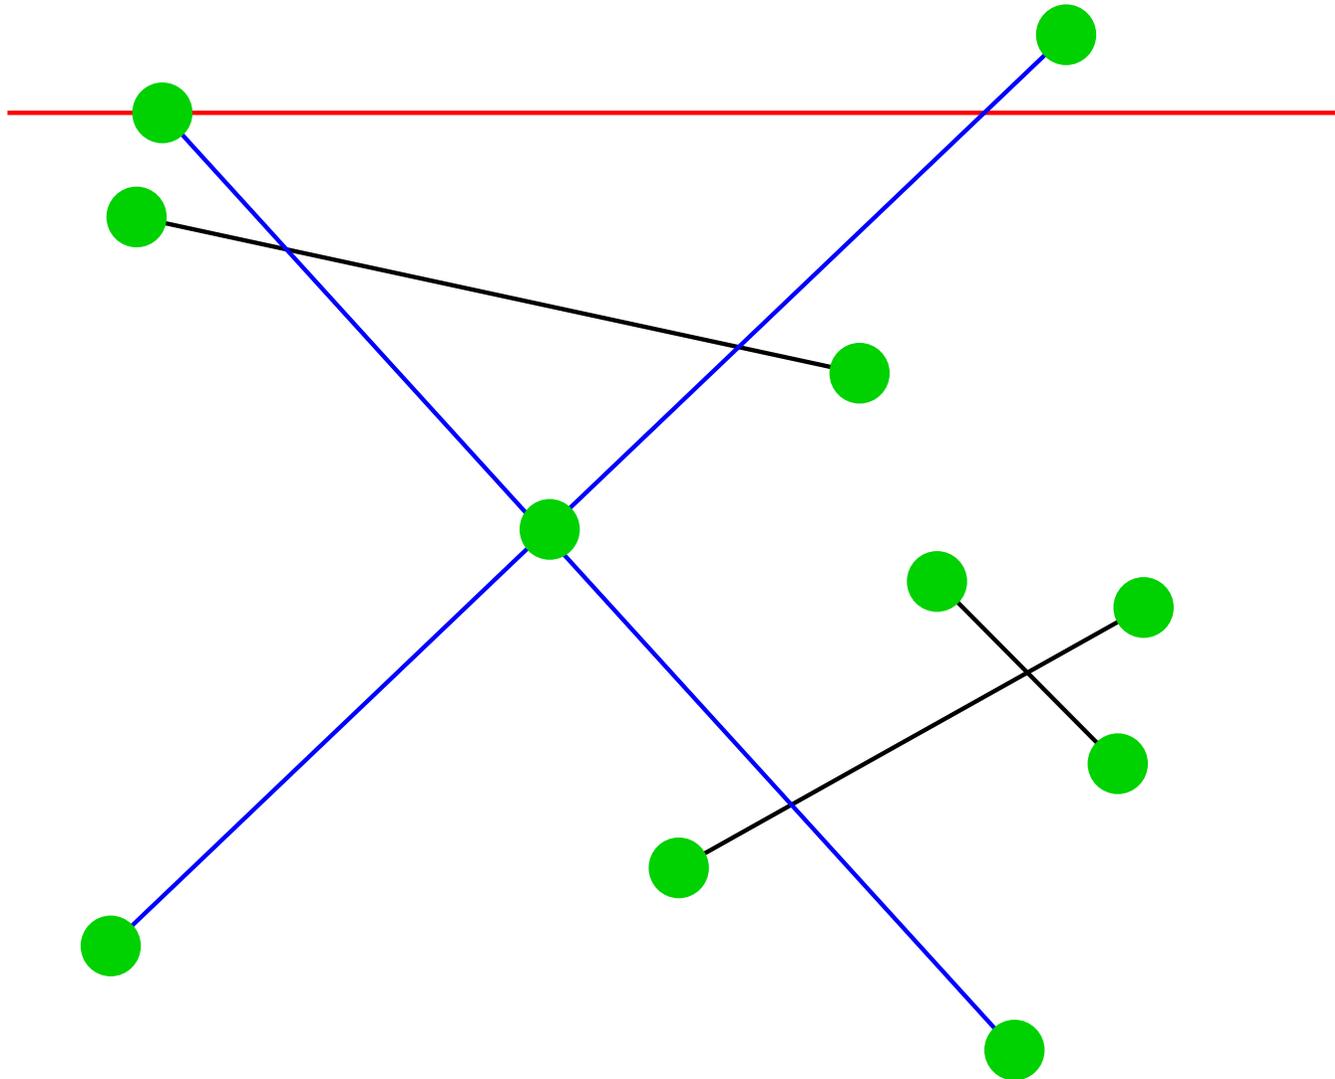
---



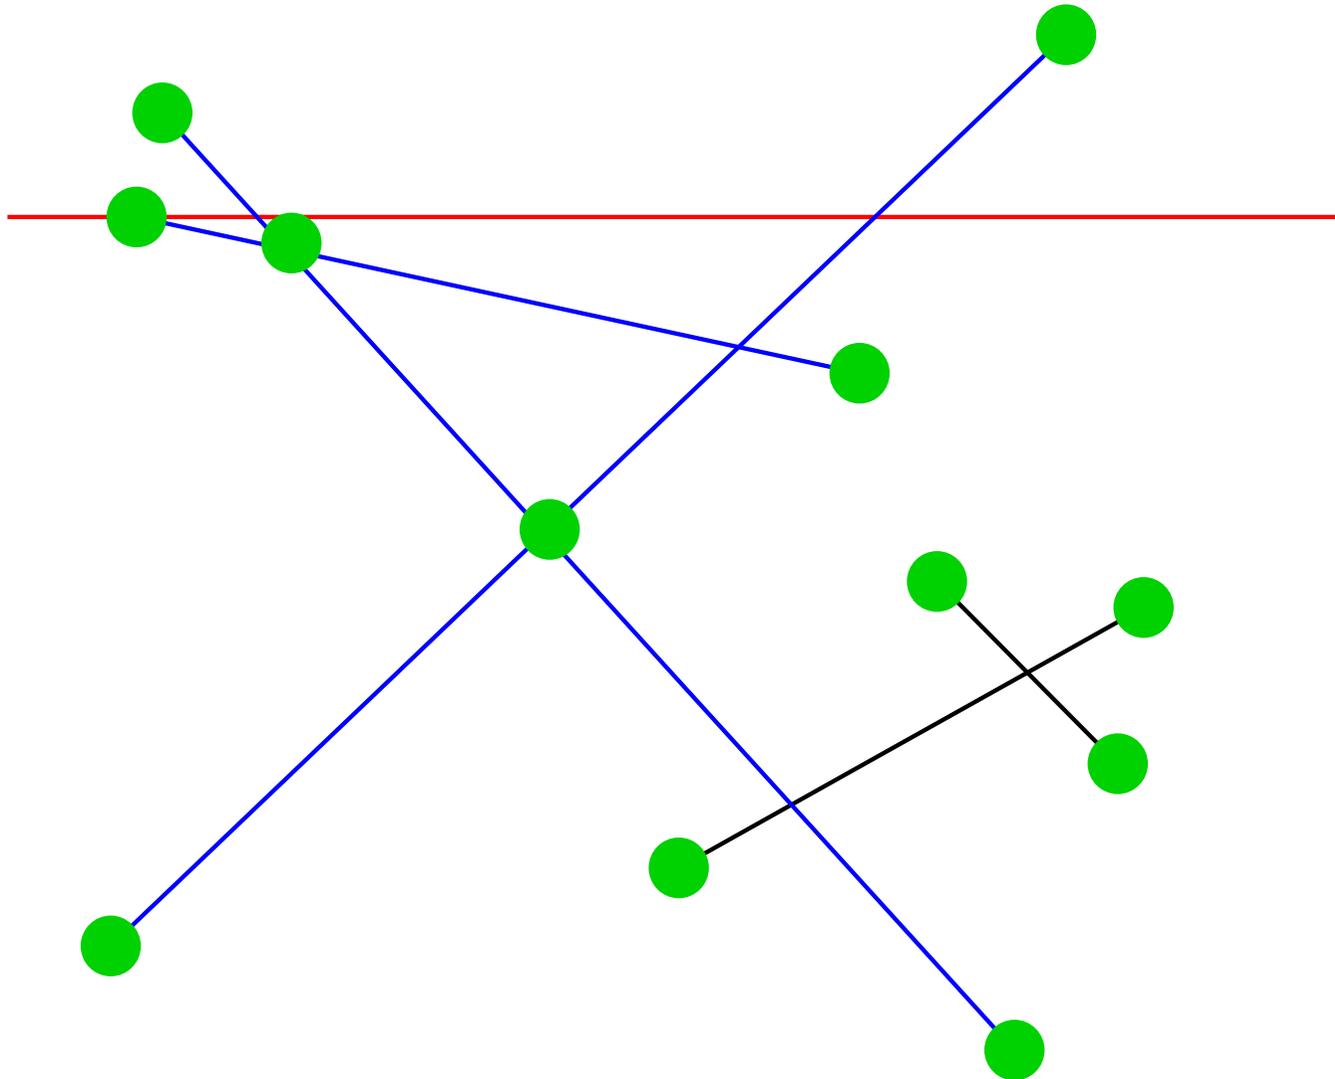
# Verallgemeinerung – Beispiel



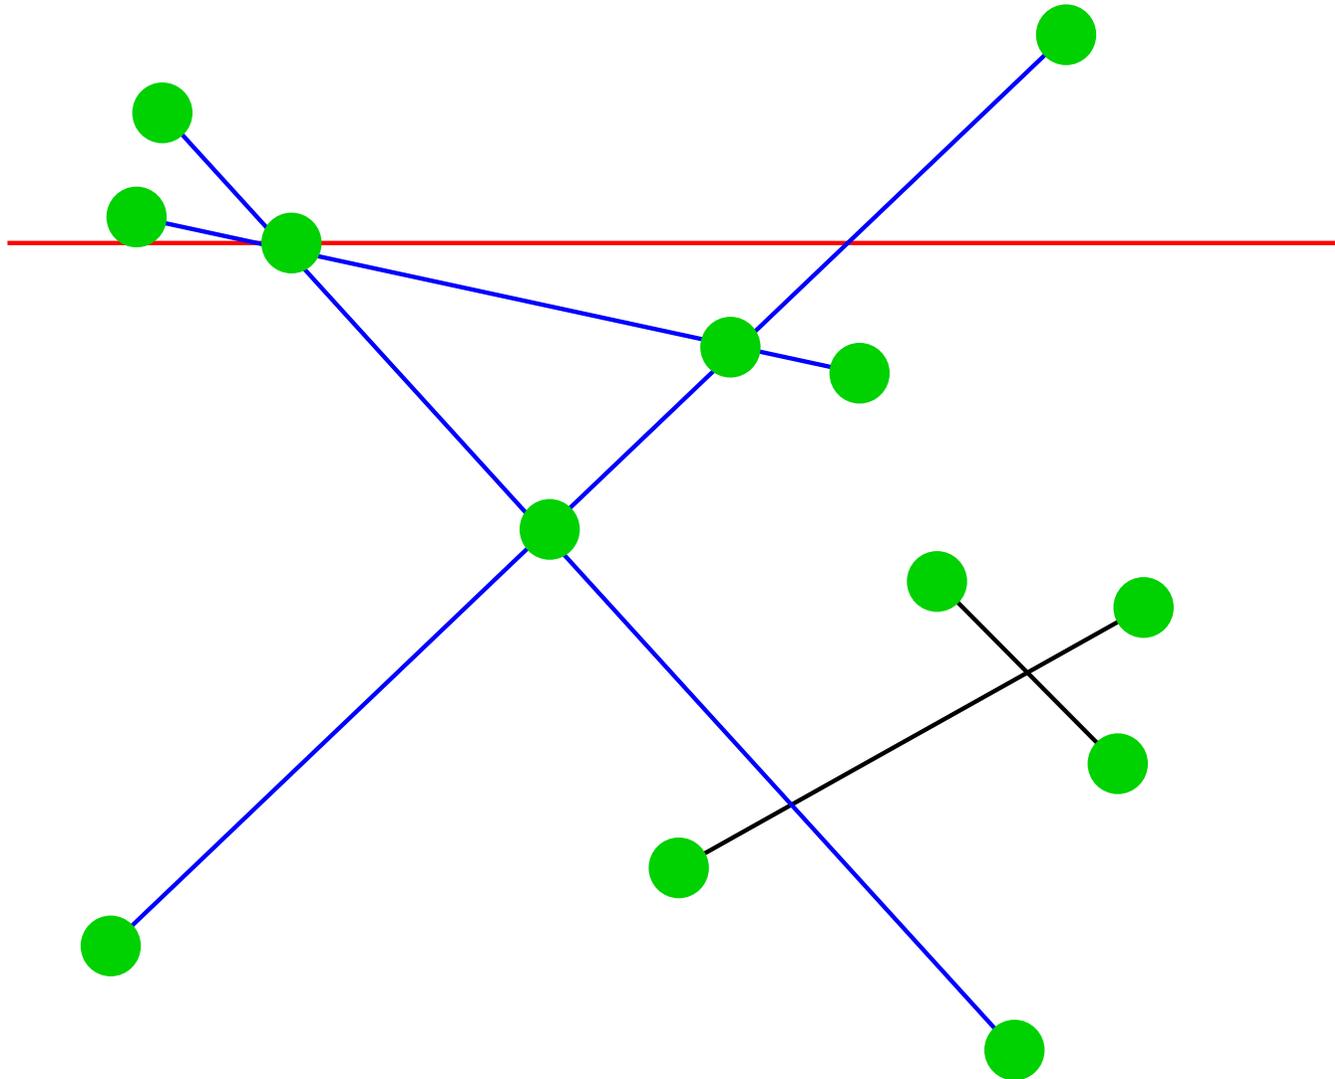
# Verallgemeinerung – Beispiel



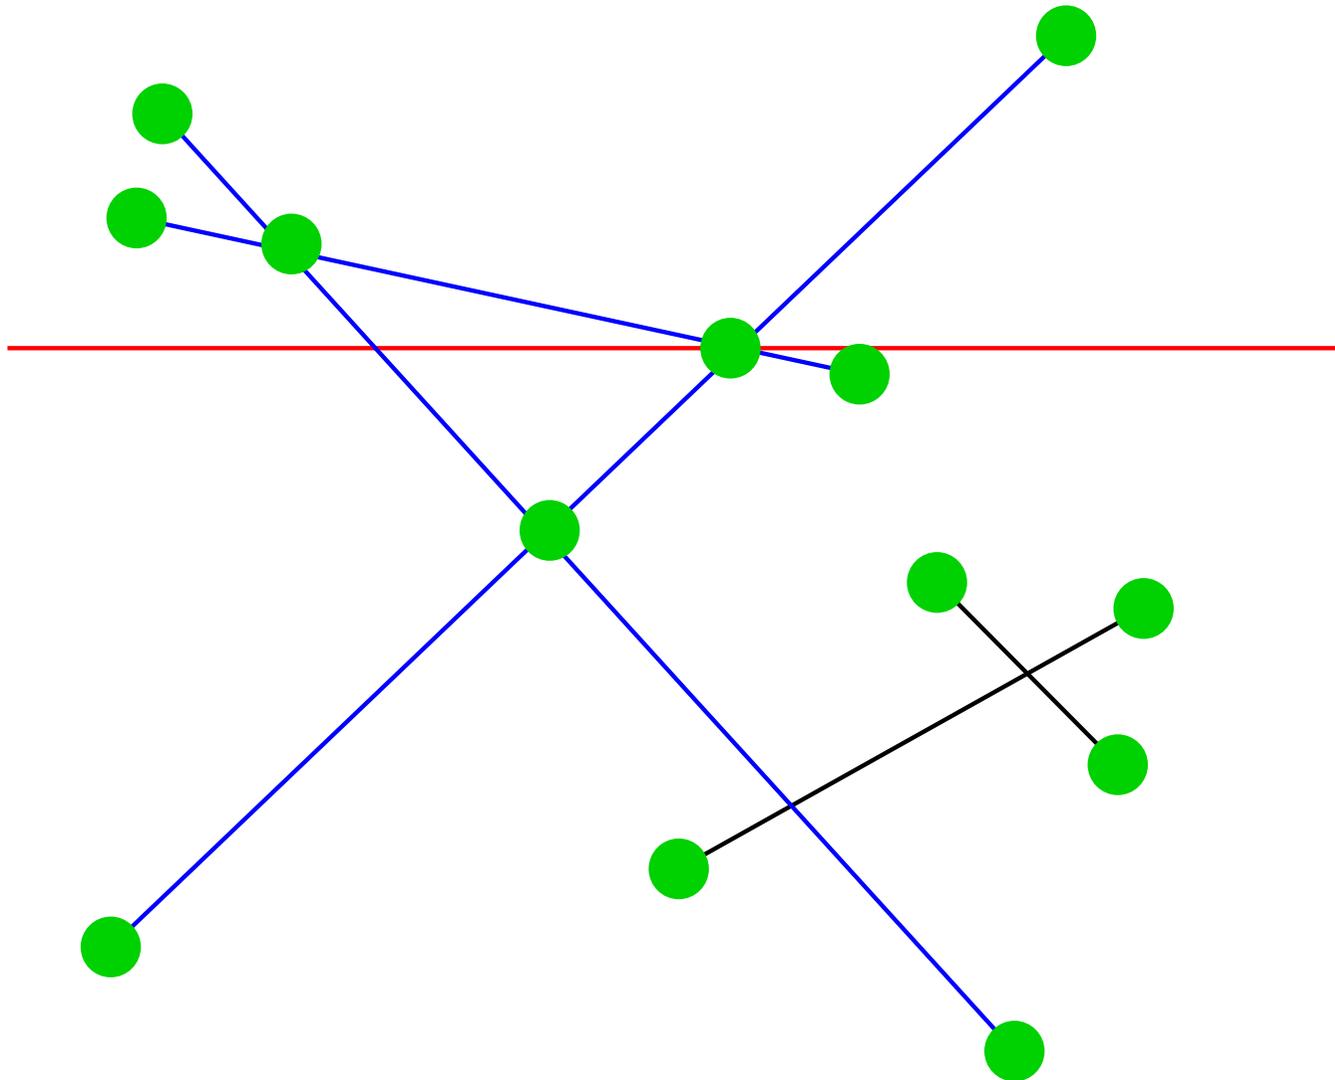
# Verallgemeinerung – Beispiel



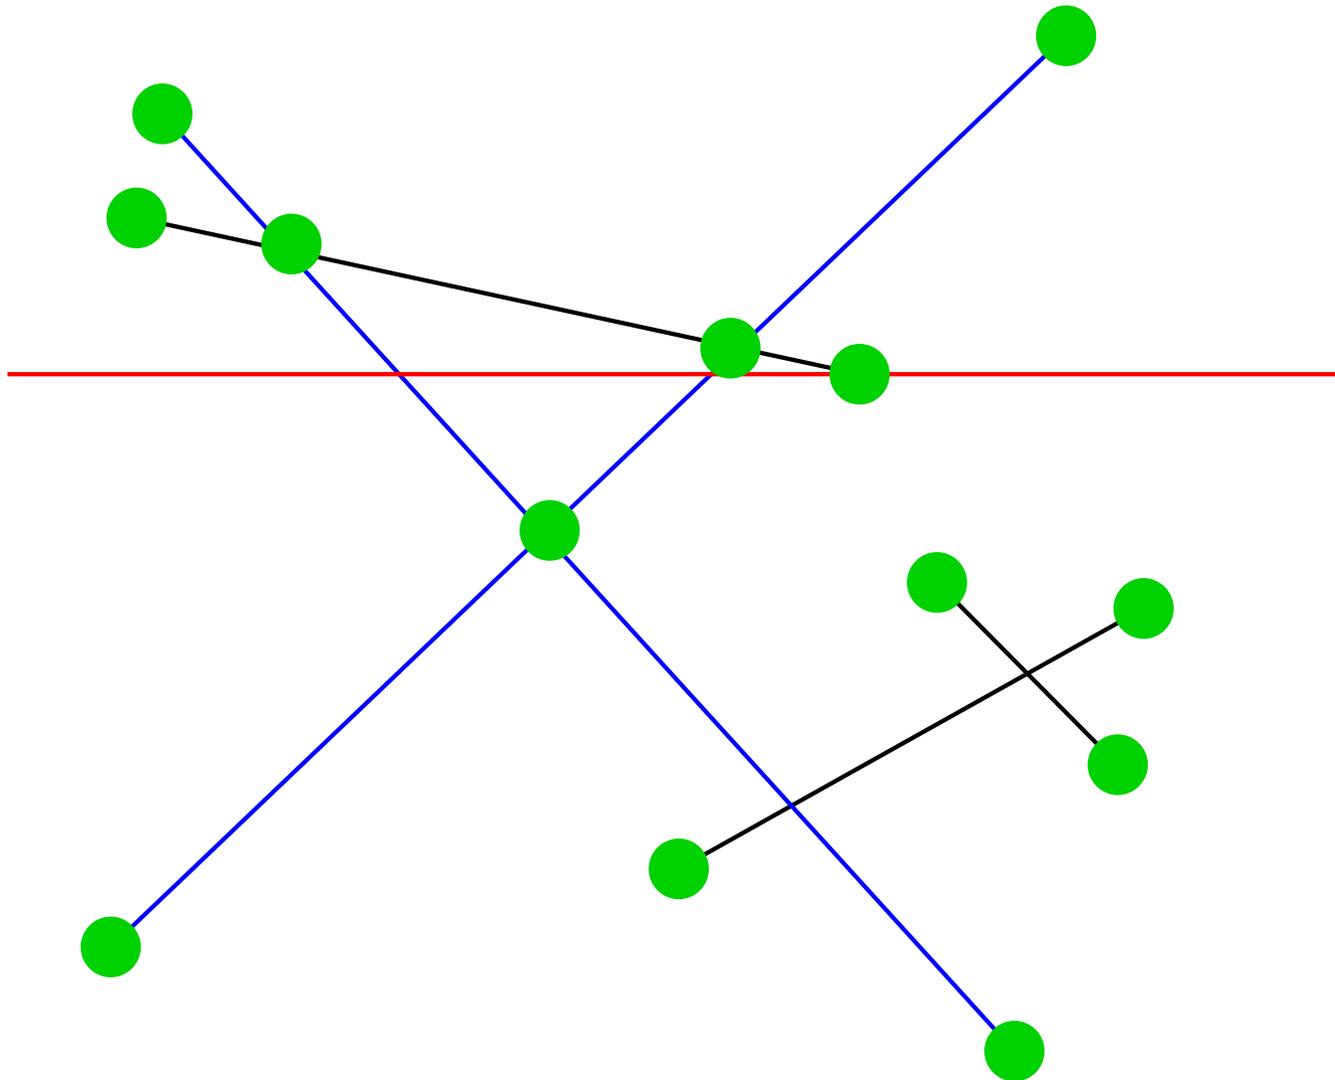
# Verallgemeinerung – Beispiel



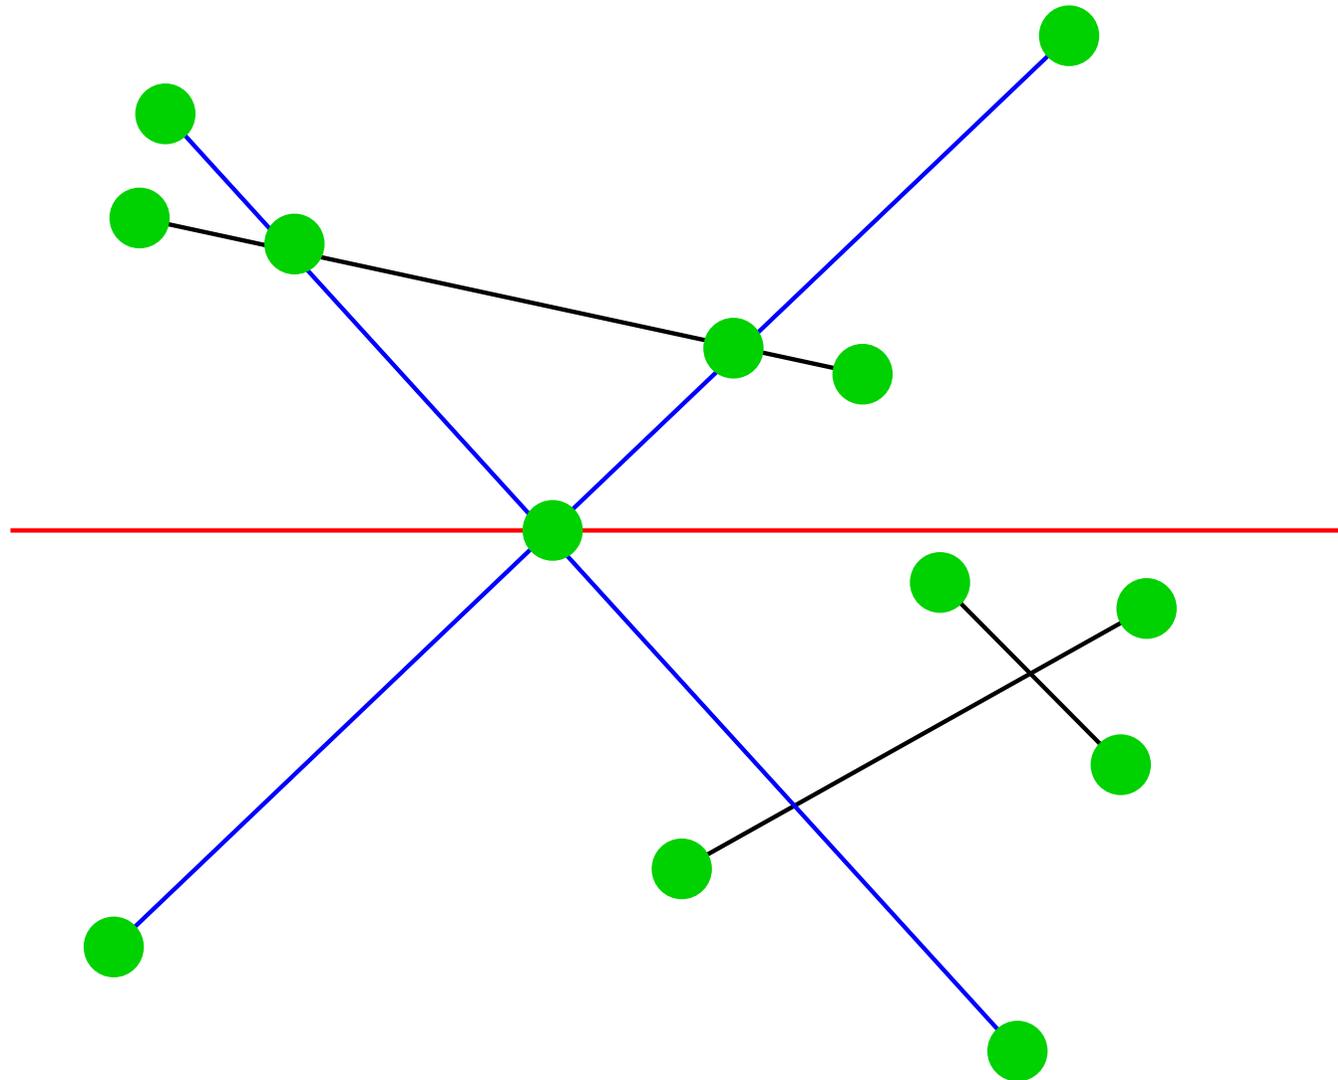
# Verallgemeinerung – Beispiel



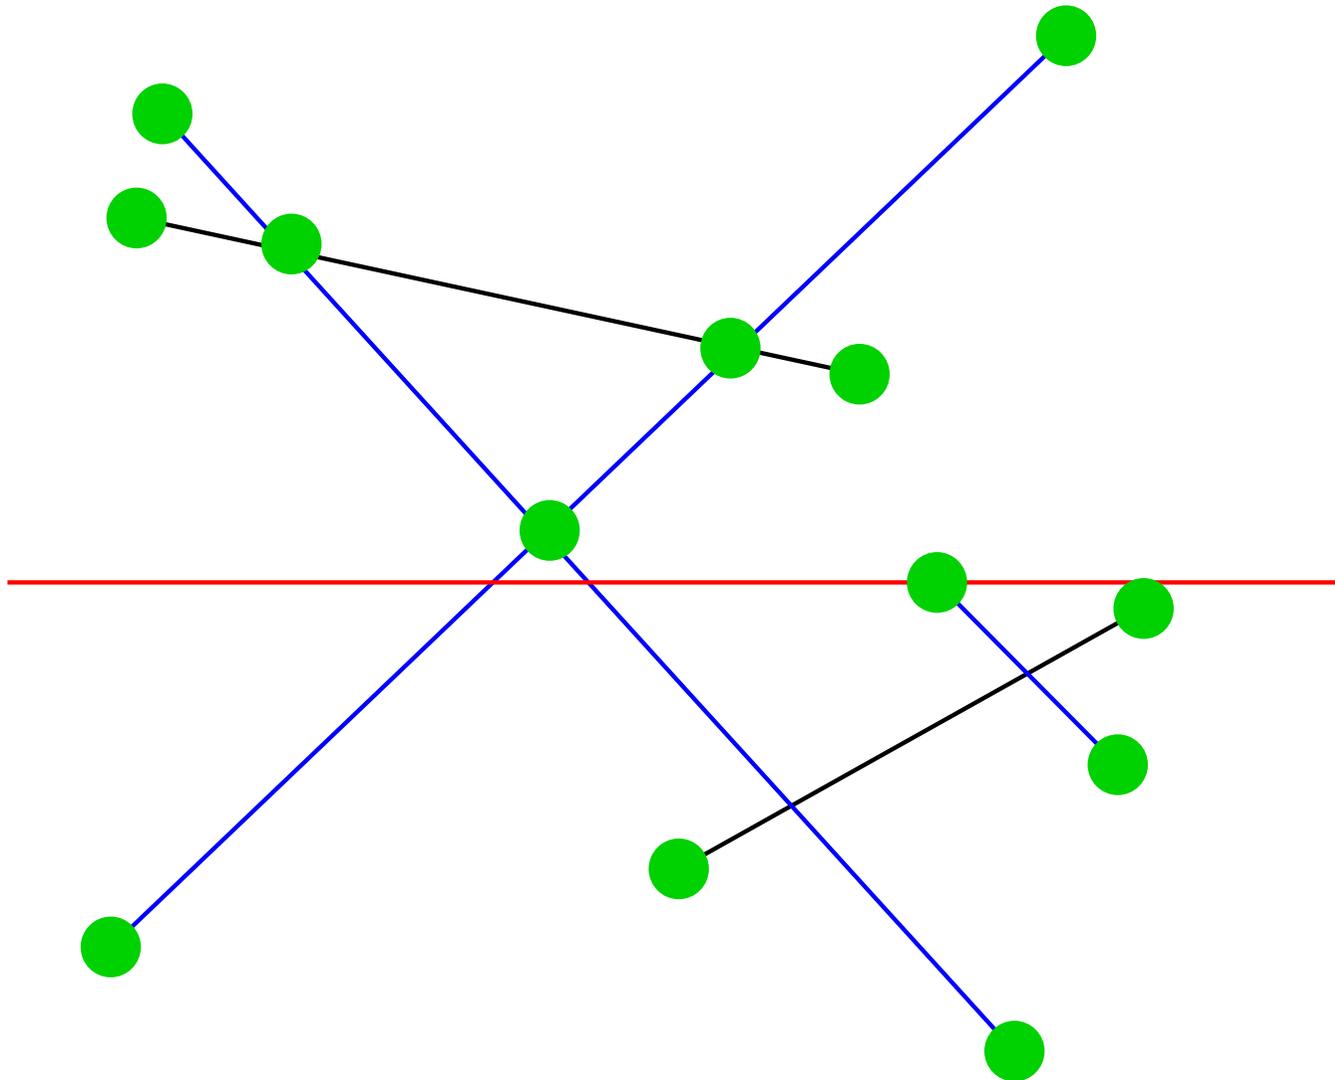
# Verallgemeinerung – Beispiel



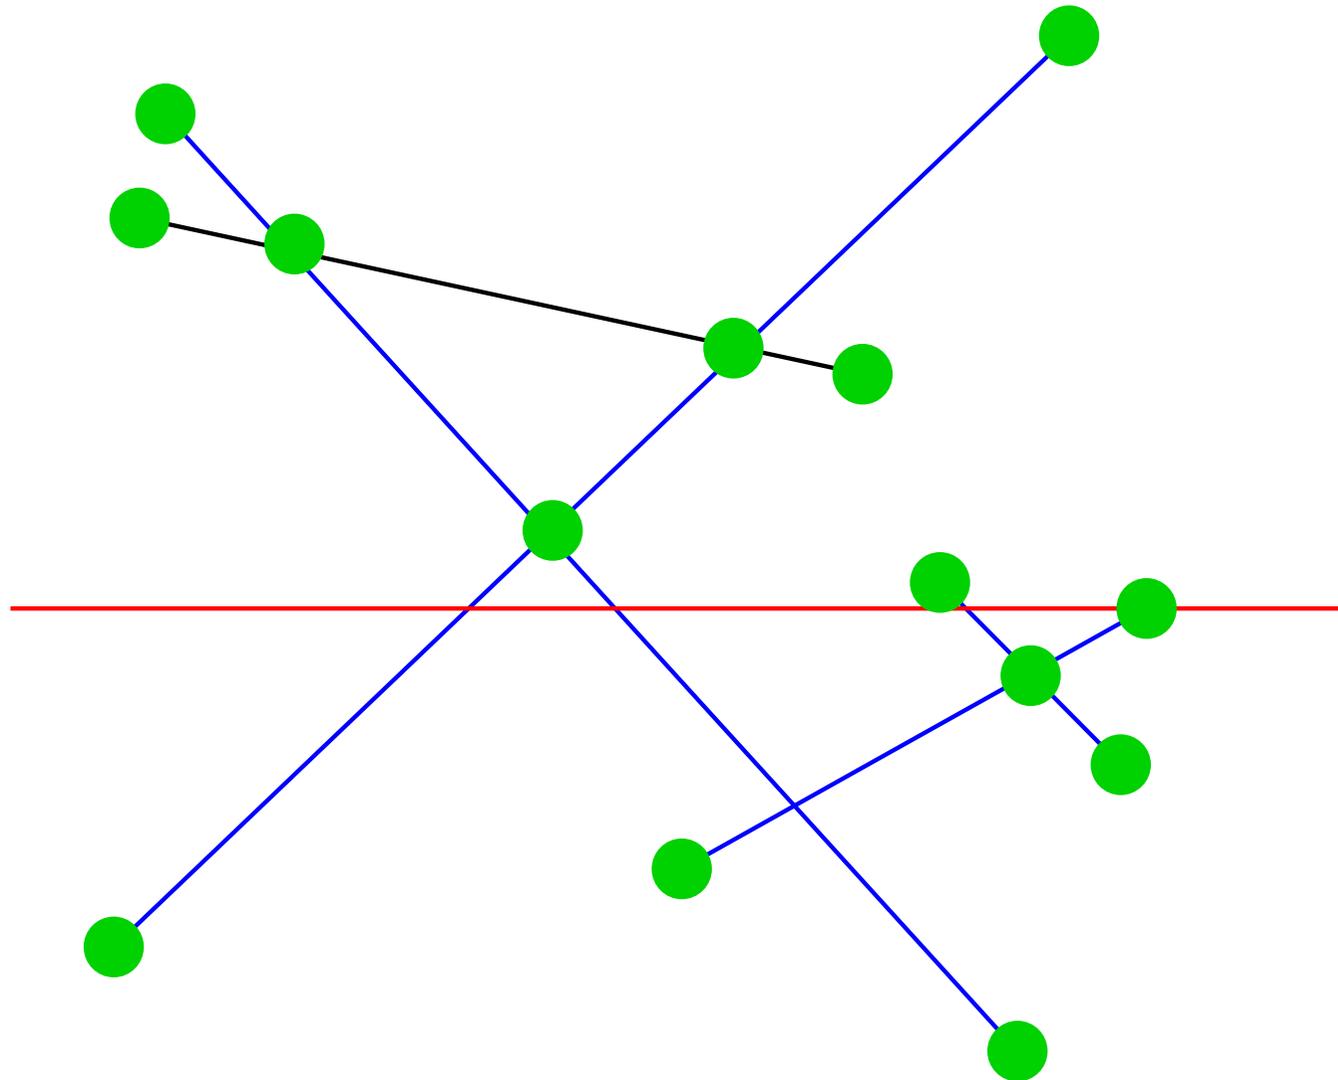
# Verallgemeinerung – Beispiel



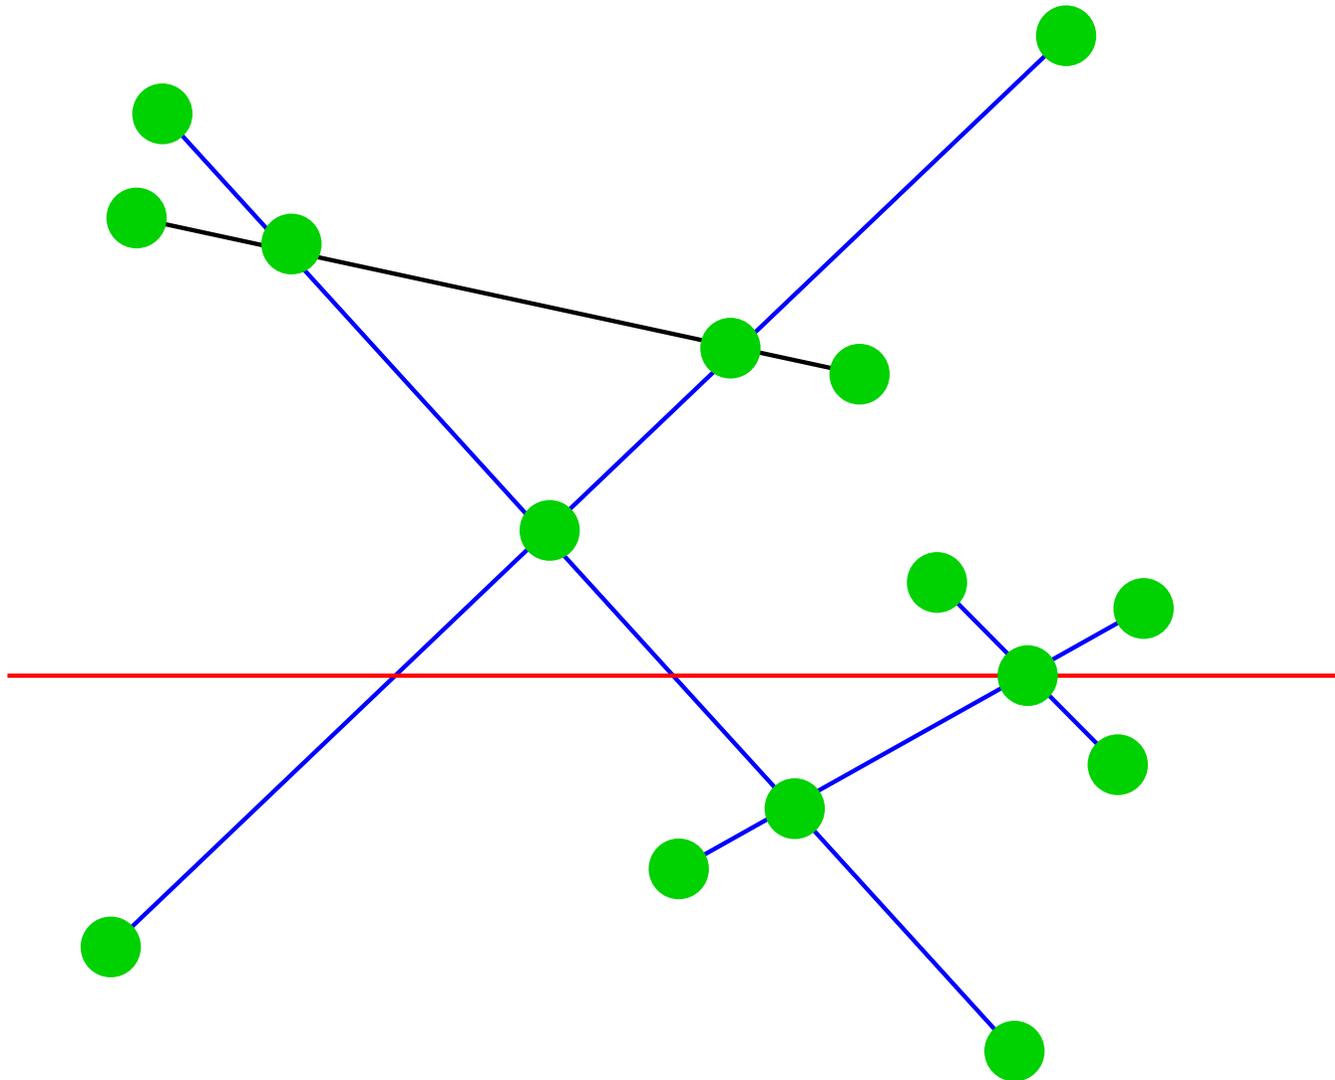
# Verallgemeinerung – Beispiel



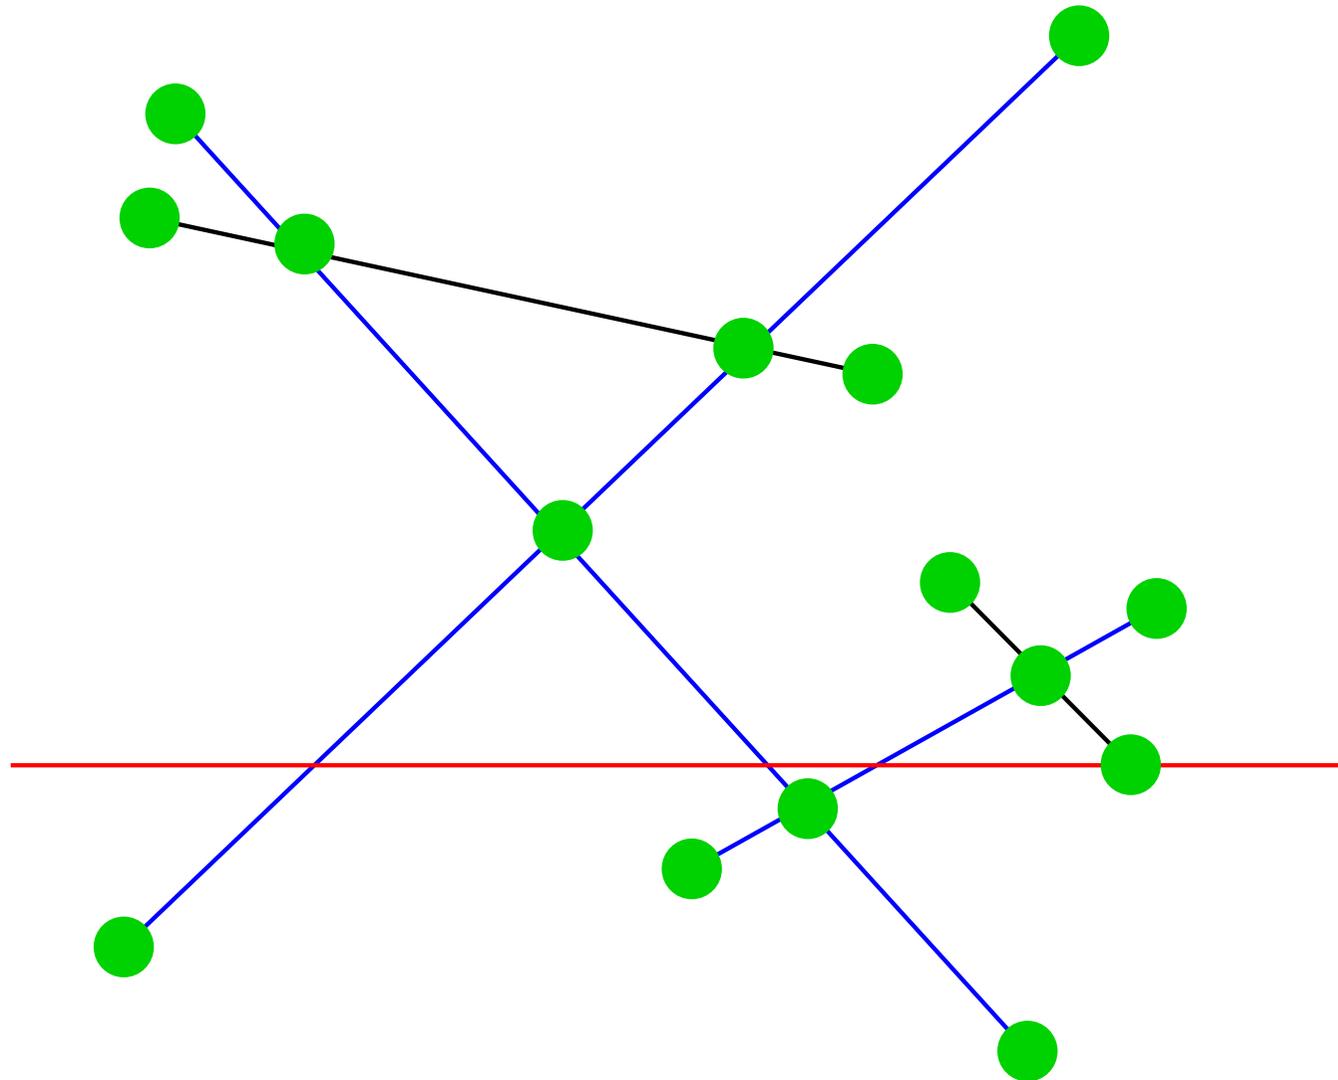
# Verallgemeinerung – Beispiel



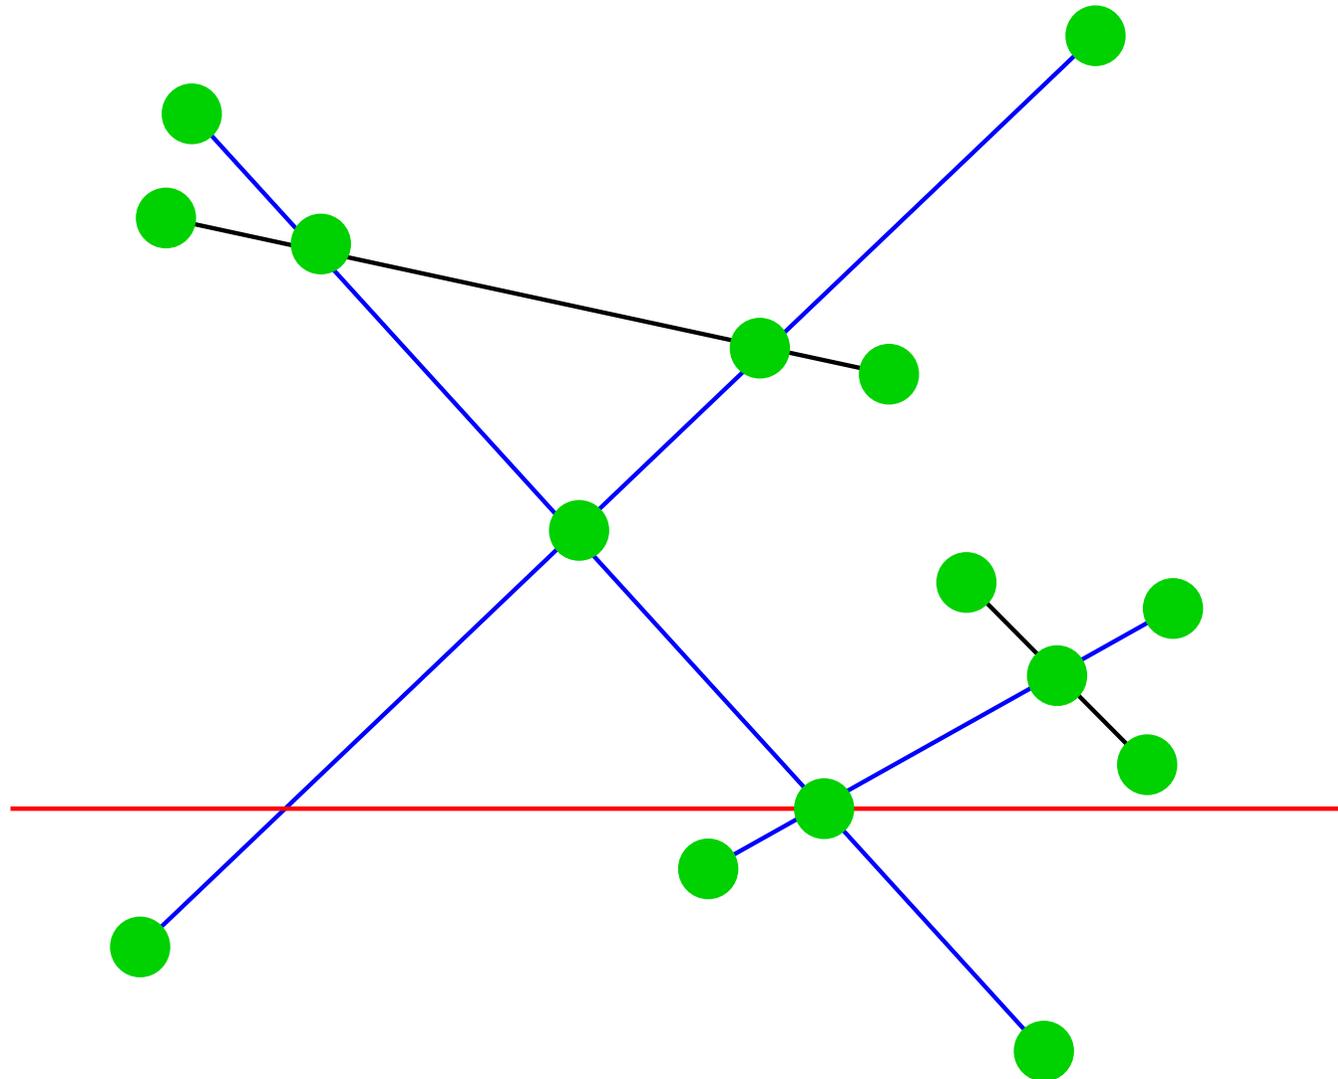
# Verallgemeinerung – Beispiel



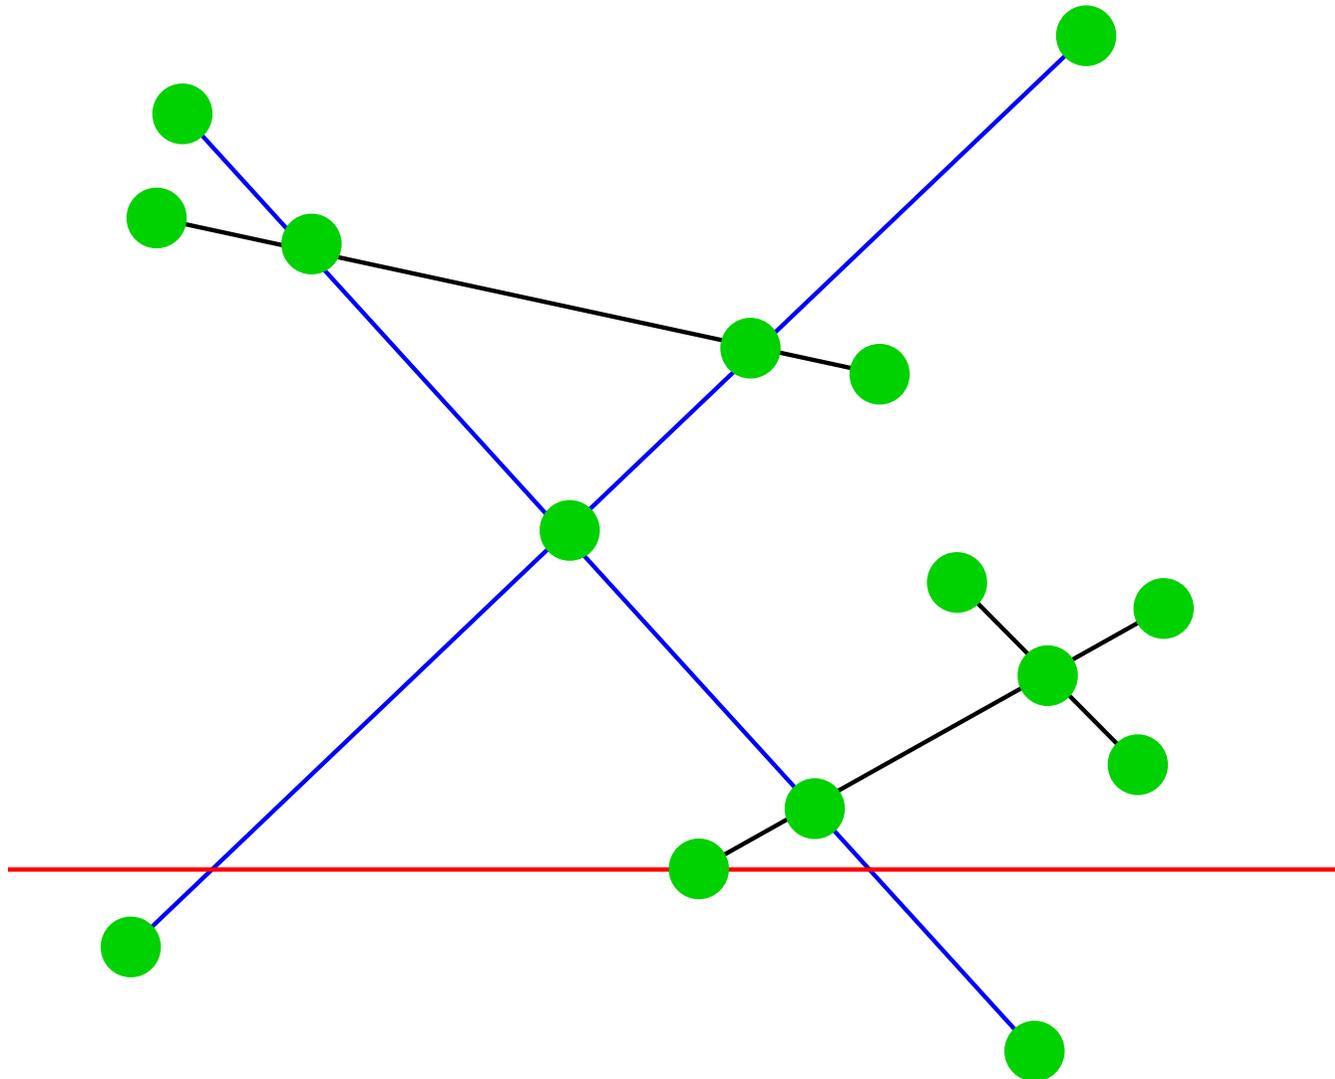
# Verallgemeinerung – Beispiel



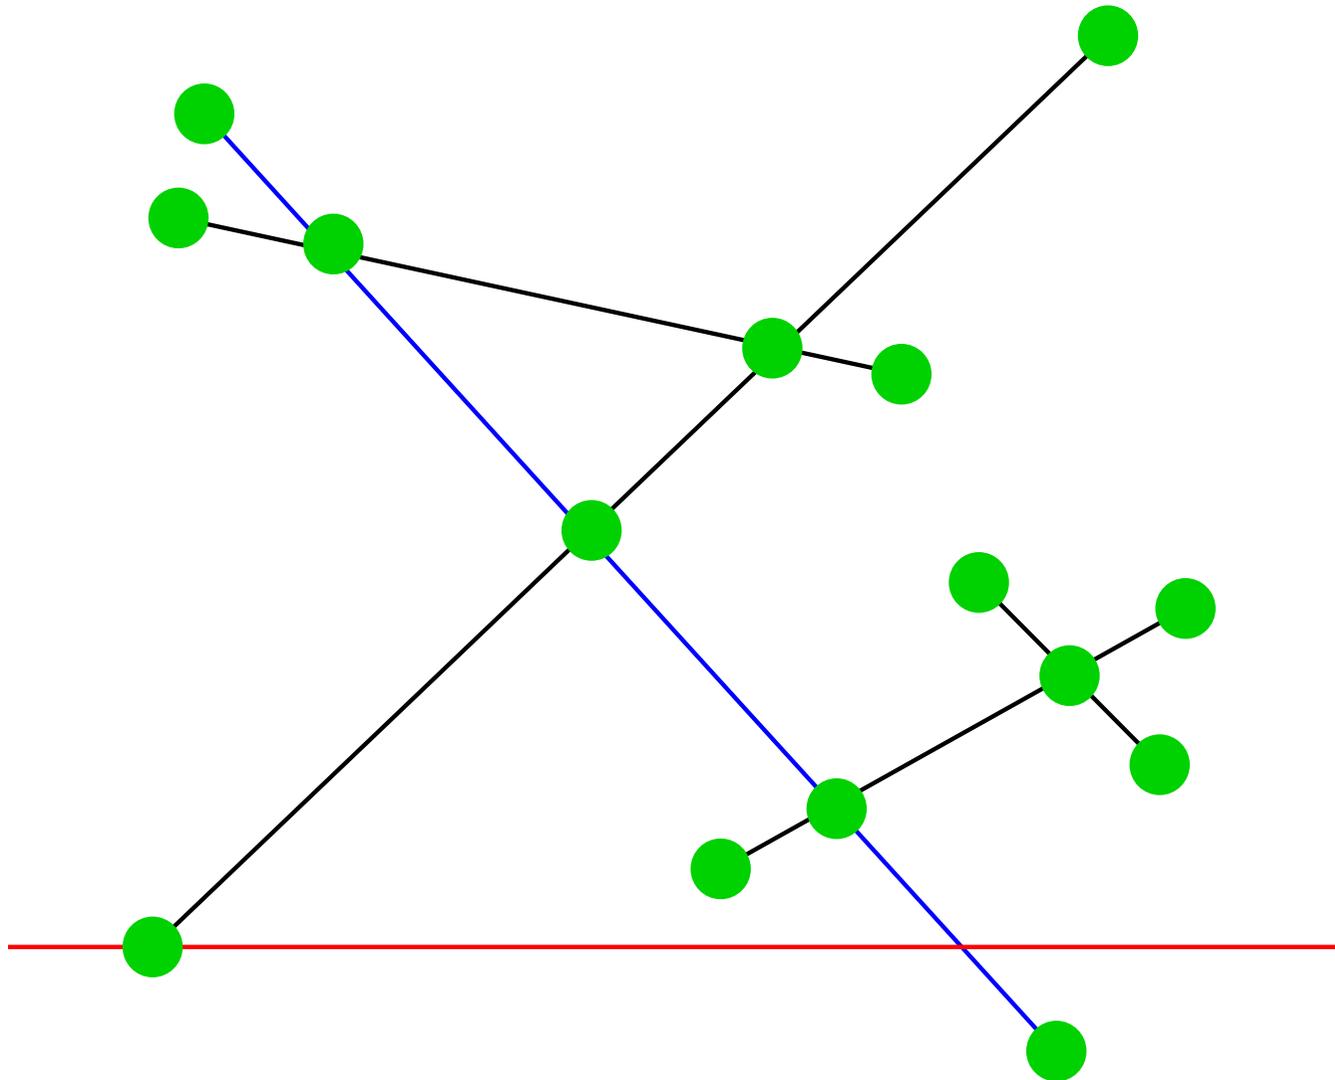
# Verallgemeinerung – Beispiel



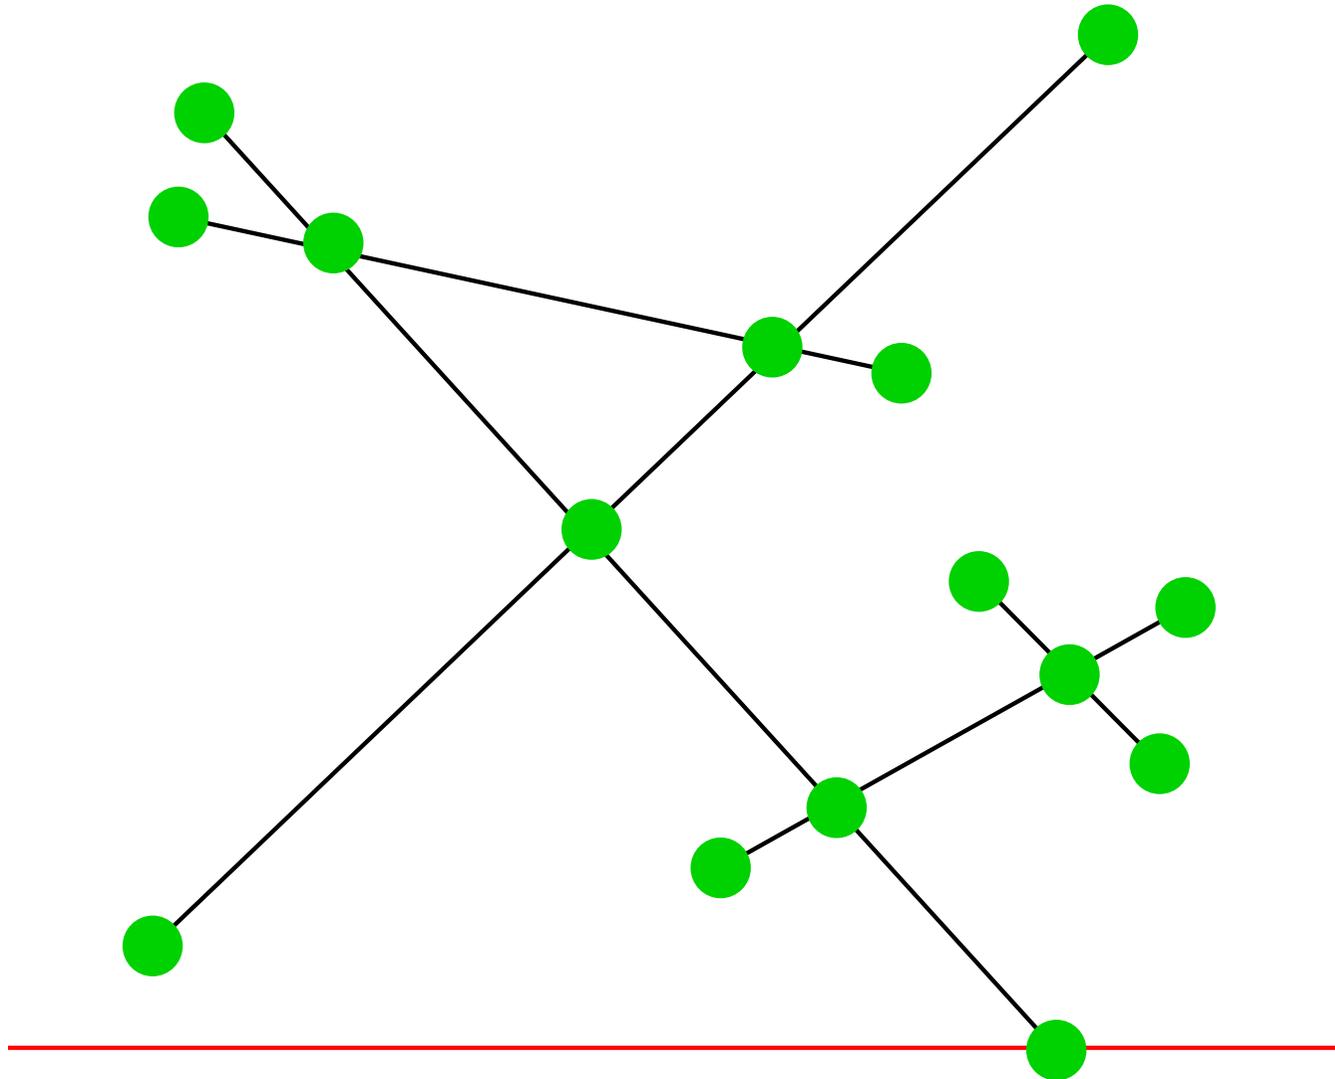
# Verallgemeinerung – Beispiel



# Verallgemeinerung – Beispiel



# Verallgemeinerung – Beispiel



# Verallgemeinerung – Analyse

Insgesamt:  $O((n + k) \log n)$

# Verallgemeinerung – jetzt (fast) wirklich

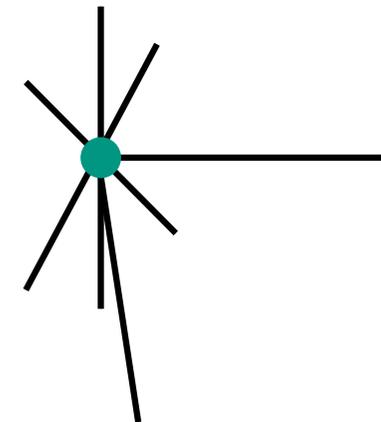
Verbleibende Annahme: Keine Überlappungen

Ordnung für  $Q$  :  $(x, y) \prec (x', y') \Leftrightarrow y > y' \vee y = y' \wedge x < x'$   
(verquere lexikographische Ordnung)

Interpretation: infinitesimal ansteigende Sweep-Line



$Q$  speichert Mengen von Ereignissen mit gleichem  $(x, y)$



handleEvent( $p = (x, y)$ )

$U :=$  segments starting at  $p$  // from  $Q$

$C :=$  segments with  $p$  in their interior // from  $T$

$L :=$  segments finishing at  $p$  // from  $Q$

**if**  $|U| + |C| + |L| \geq 2$  **then** report intersection @  $p$

$T.remove(L \cup C)$

$T.insert(C \cup U)$  such that order just below  $p$  is correct

**if**  $U \cup C = \emptyset$  **then**

    findNewEvent( $T.findPred(p), T.findSucc(p), p$ )

**else**

    findNewEvent( $T.findPred(p), T.findLeftmost(p), p$ )

    findNewEvent( $T.findRightmost(p), T.findSucc(p), p$ )

findNewEvent( $s, t, p$ )

**if**  $s$  and  $t$  intersect at a point  $p' \succ p$  **then**

**if**  $p' \notin Q$  **then**  $Q.\text{insert}(p')$

# Überlappungen finden

Für jede Strecke  $s$  berechne die Gerade  $g(s)$ , auf der  $s$  liegt

Sortiere  $S$  nach  $g(s)$

1D Überlappungsproblem für jede auftretende Gerade.

# Platzverbrauch

Im Moment:  $\Theta(n + k)$

Reduktion auf  $O(n)$ :

lösche Schnittpunkte zwischen nicht benachbarten Strecken aus  $T$ .

Die werden ohnehin wieder eingefügt wenn sie wieder benachbart werden.

## Mehr Linienschnitt

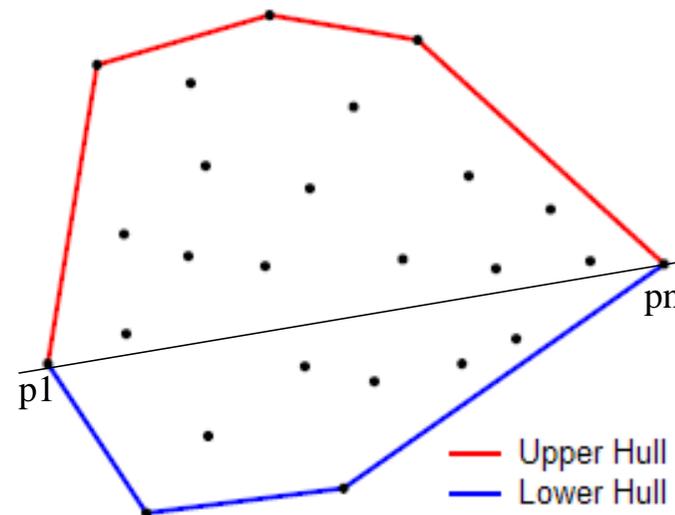
- [Bentley Ottmann 1979] Zeit  $O((n + k) \log n)$
- [Chazelle Edelsbrunner 1988] Zeit  $O(n \log n + k)$
- [Pach Sharir 1991] Zeit  $O((n + k) \log n)$ , Platz  $O(n)$
- [Mulmuley 1988] erwartete Zeit  $O(n \log n + k)$ , Platz  $O(n)$
- [Balaban 1995] Zeit  $O(n \log n + k)$ , Platz  $O(n)$

## 12.2 2D Konvexe Hülle

**Gegeben:** Menge  $P = \{p_1, \dots, p_n\}$  von Punkten in  $\mathbb{R}^2$

**Gesucht:** Konvexes Polygon  $K$  mit Eckpunkten aus  $P$  und  $P \subseteq K$ .

Wir geben einen einfachen Algorithmus, der in Zeit  $O(\text{sort}(n))$  läuft.



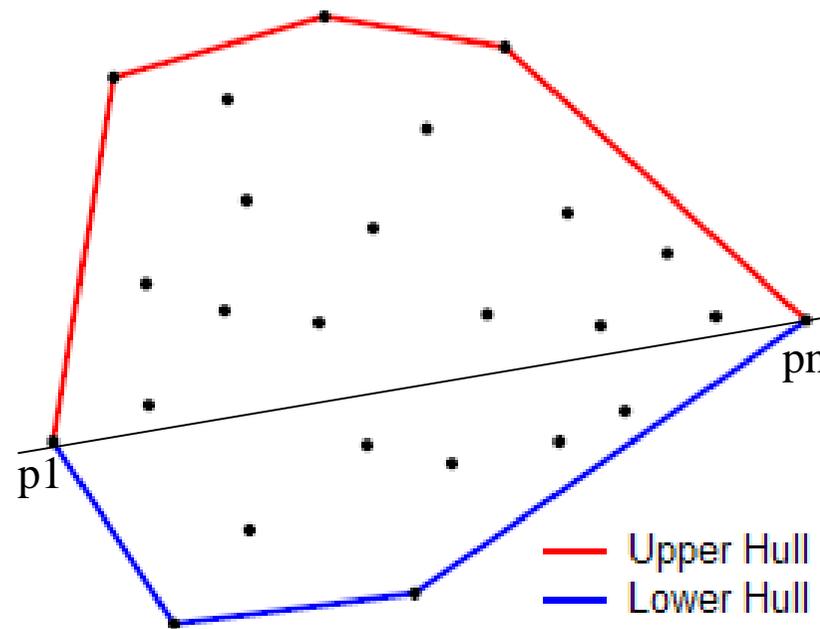
# Konvexe Hülle

sortiere  $P$  lexikographisch nach  $(x, y)$ , d.h., ab jetzt

$$p_1 < p_2 < \dots < p_n$$

OBdA:

Wir berechnen nur die obere Hülle von Punkten oberhalb von  $\overline{p_1 p_n}$



# Graham's Scan [Graham 1972, Andrew 1979]

**Function** upperHull( $p_1, \dots, p_n$ )

$L = \langle p_n, p_1, p_2 \rangle$  : Stack of Point

**invariant**  $L$  is the upper hull of  $\langle p_n, p_1, \dots, p_i \rangle$

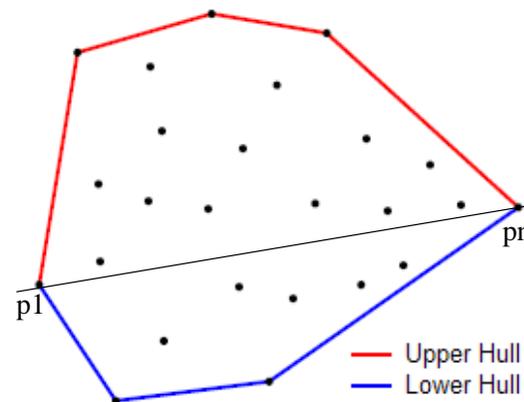
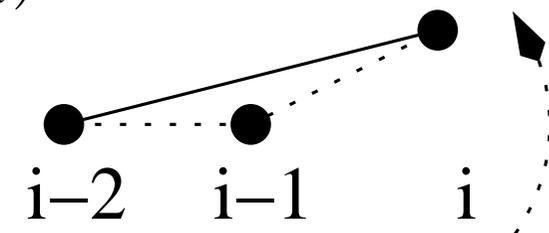
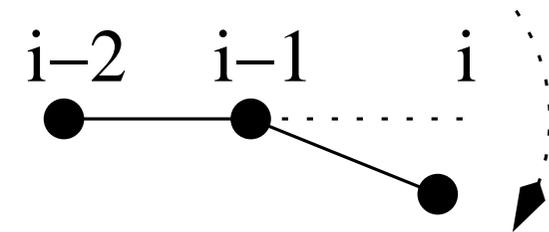
**for**  $i := 3$  **to**  $n$  **do**

**while**  $\neg \text{rightTurn}(L.\text{secondButLast}, L.\text{last}, p_i)$  **do**

$L.\text{pop}$

$L := L \circ \langle p_i \rangle$

**return**  $L$



# Graham's Scan – Beispiel

**Function** upperHull( $p_1, \dots, p_n$ )

$L = \langle p_n, p_1, p_2 \rangle$  : Stack **of** Point

**invariant**  $L$  is the upper hull of  $\langle p_n, p_1, \dots, p_i \rangle$

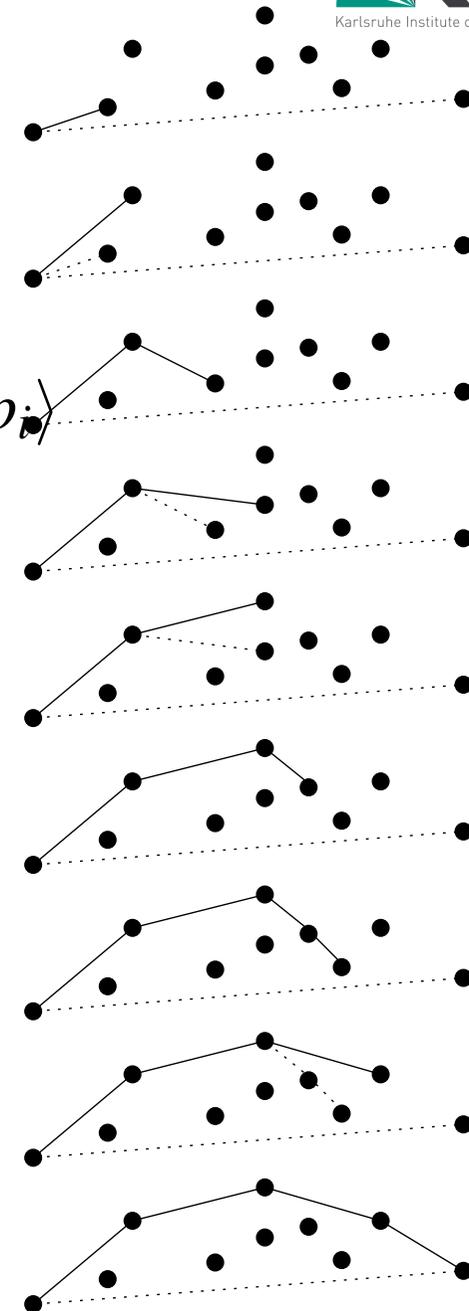
**for**  $i := 3$  **to**  $n$  **do**

**while**  $\neg \text{rightTurn}(L.\text{secondButlast},$   
         $L.\text{last}, p_i)$  **do**

$L.\text{pop}$

$L := L \circ \langle p_i \rangle$

**return**  $L$



## Graham's Scan – Analyse

**Function** upperHull( $p_1, \dots, p_n$ )

$L = \langle p_n, p_1, p_2 \rangle$  : Stack **of** Point

**invariant**  $L$  is the upper hull of  $\langle p_n, p_1, \dots, p_i \rangle$

**for**  $i := 3$  **to**  $n$  **do**

**while**  $\neg \text{rightTurn}(L.\text{secondButLast}, L.\text{last}, p_i)$  **do**

$L.\text{pop}$

$L := L \circ \langle p_i \rangle$

**return**  $L$

Sortieren  $+O(n)$

Wieviele Iterationen der While-Schleife insgesamt?

## 3D Konvexe Hülle

Geht in Zeit  $O(n \log n)$  [Preparata Hong 1977]

**Konvexe Hülle,  $d \geq 4$**

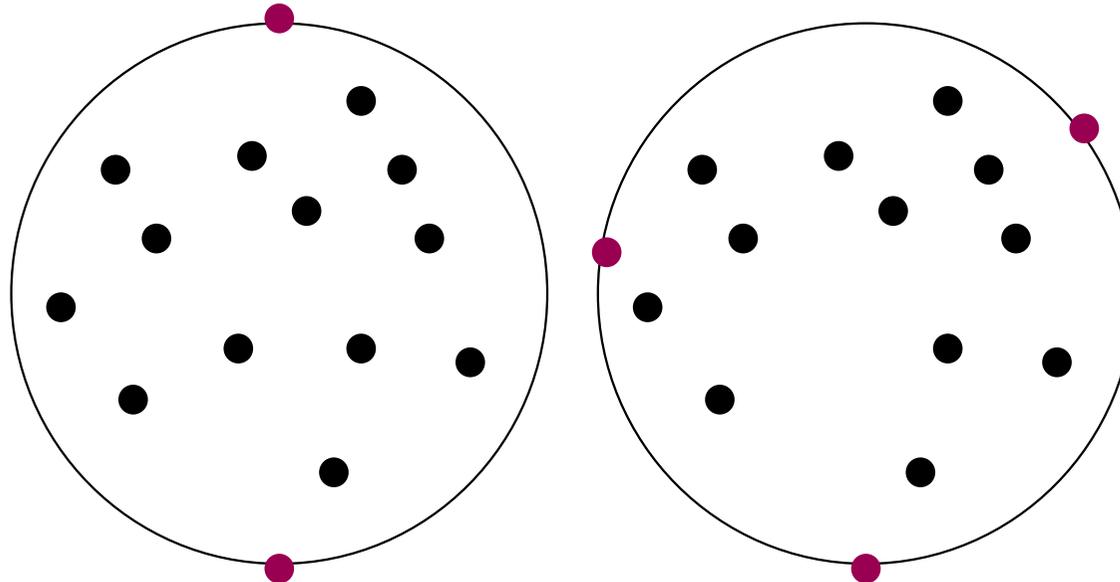
Ausgabekomplexität  $O\left(n^{\lfloor d/2 \rfloor}\right)$

## 12.3 Kleinste einschließende Kugel

**Gegeben:** Menge  $P = \{p_1, \dots, p_n\}$  von Punkten in  $\mathbb{R}^d$

**Gesucht:** Kugel  $K$  mit minimalem Radius, so dass  $P \subseteq K$ .

Wir geben einen einfachen Algorithmus, der in erwarteter Zeit  $O(n)$  läuft. [\[Welzl 1991\]](#).



**Function** `smallestEnclosingBallWithPoints`( $P, Q$ )

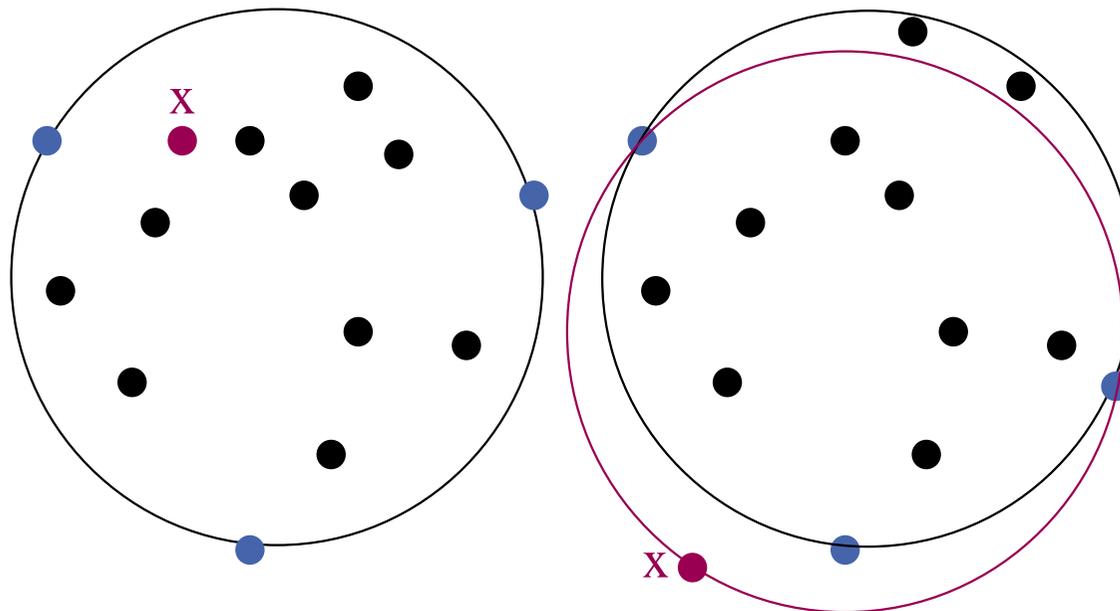
**if**  $|P| = 0 \vee |Q| = d + 1$  **then return** `ball`( $Q$ )

pick random  $x \in P$

$B :=$  `smallestEnclosingBallWithPoints`( $P \setminus \{x\}, Q$ )

**if**  $x \in B$  **then return**  $B$

**return** `smallestEnclosingBallWithPoints`( $P \setminus \{x\}, Q \cup \{x\}$ )



## Kleinste einschließende Kugel – Korrektheit

**Function** `smallestEnclosingBallWithPoints( $P, Q$ )`

**if**  $|P| = 1 \vee |Q| = d + 1$  **then return** `ball( $Q$ )`

pick random  $x \in P$

$B :=$  `smallestEnclosingBallWithPoints( $P \setminus \{x\}, Q$ )`

**if**  $x \in B$  **then return**  $B$

**return** `smallestEnclosingBallWithPoints( $P \setminus \{x\}, Q \cup \{x\}$ )`

z.Z.:  $x \notin B \rightarrow x$  ist auf dem Rand von  $\text{sEB}(P)$

Wir zeigen Kontraposition:

$x$  nicht auf dem Rand von  $\text{sEB}(P)$

$\rightarrow \text{sEB}(P) = \text{sEB}(P \setminus \{x\}) = B$

z.Z.: sEBs sind eindeutig!

Also  $x \in B$

**Lemma:**  $\text{sEB}(P)$  ist eindeutig bestimmt.

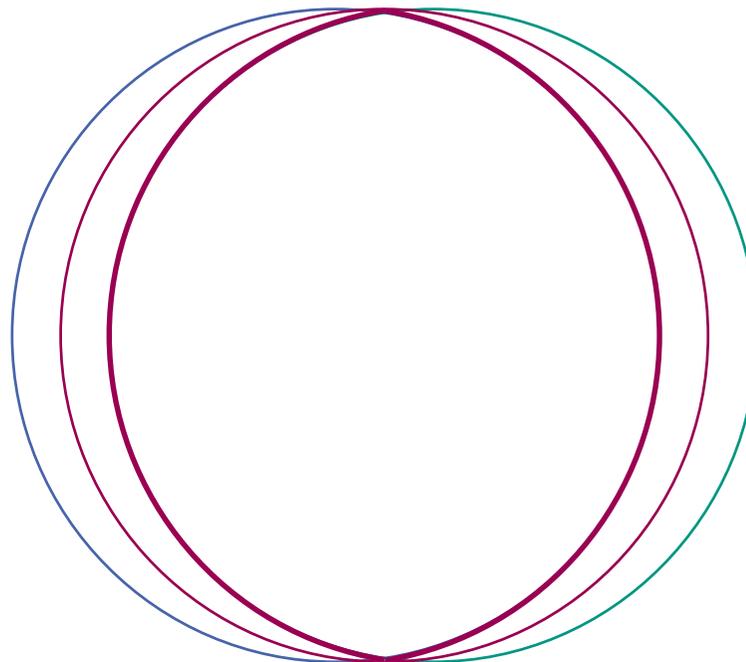
**Beweis:** Annahme,  $\exists \text{sEBs } B_1 \neq B_2$

$$\longrightarrow P \subseteq B_1 \wedge P \subseteq B_2$$

$$\longrightarrow P \subseteq B_1 \cap B_2 \subseteq \text{sEB}(B_1 \cap B_2) =: B$$

Aber dann ist  $\text{radius}(B) < \text{radius}(B_1)$

Widerspruch zur Annahme, dass  $B_1$  eine sEB ist. □



## Kleinste einschließende Kugel – Analyse

Wir zählen die erwartete Anzahl der Tests  $x \in B$ ,  $T(p, q)$ .

$$T(p, d+1) = T(1, p) = 0 \quad \text{Basis der Rekurrenz}$$

$$\begin{aligned} T(p, q) &\leq 1 + T(p-1, q) + \mathbb{P}[x \notin B] T(p, q+1) \\ &\leq 1 + T(p-1, q) + \frac{d+1-q}{p} T(p, q+1) \end{aligned}$$

## Kleinste einschließende Kugel – Analyse, $d = 2$

$$T(p, d+1) = T(1, p) = 0$$

$$T(p, q) \leq 1 + T(p-1, q) + \frac{d+1-q}{p} T(p, q+1)$$

$$T(p, 2) \leq 1 + T(p-1, 2) + \frac{1}{p} T(p, 3) \leq 1 + T(p-1, 2) \leq p$$

$$T(p, 1) \leq 1 + T(p-1, 1) + \frac{2}{p} T(p, 2)$$

$$\leq 1 + T(p-1, 1) + \frac{2}{p} p = 3 + T(p-1, 1) \leq 3p$$

$$T(p, 0) \leq 1 + T(p-1, 0) + \frac{3}{p} T(p, 1)$$

$$\leq 1 + T(p-1, 0) + \frac{3}{p} 3p = 10 + T(p-1, 0) \leq 10p$$

# Kleinste einschließende Kugel – Analyse

$d$	$T(p, 0)$
1	$3n$
2	$10n$
3	$41n$
4	$206n$

Allgemein  $T(p, 0) \geq d!n$

# Ähnliche Randomisierte Linearzeitalgorithmen

- Lineare Programmierung mit konstantem  $d$  [Seidel 1991]
- Kleinstes einschließendes Ellipsoid, Kreisring, . . .
- Support-Vector-Machines (maschinelles Lernen)
- Alles wo (LP-type problem [Sharir Welzl 1992])
  - $O(1)$  Objekte das Optimum festlegen
  - Objekt  $x$  hinzufügen
    - Lösung bleibt gleich oder ist an Lösungsdef. beteiligt

## 12.4 2D Bereichssuche (range search)

**Daten:**  $P = \{p_1, \dots, p_n\} \subseteq \mathbb{R}^2$

**Anfragen:** achsenparallele Rechtecke  $Q = [x, x'] \times [y, y']$

finde  $P \cap Q$  (range reporting)

oder  $k = |P \cap Q|$  (range counting)

Vorverarbeitung erlaubt.

Vorverarbeitungszeit?  $O(n \log n)$

Platz?  $O(n) ?$

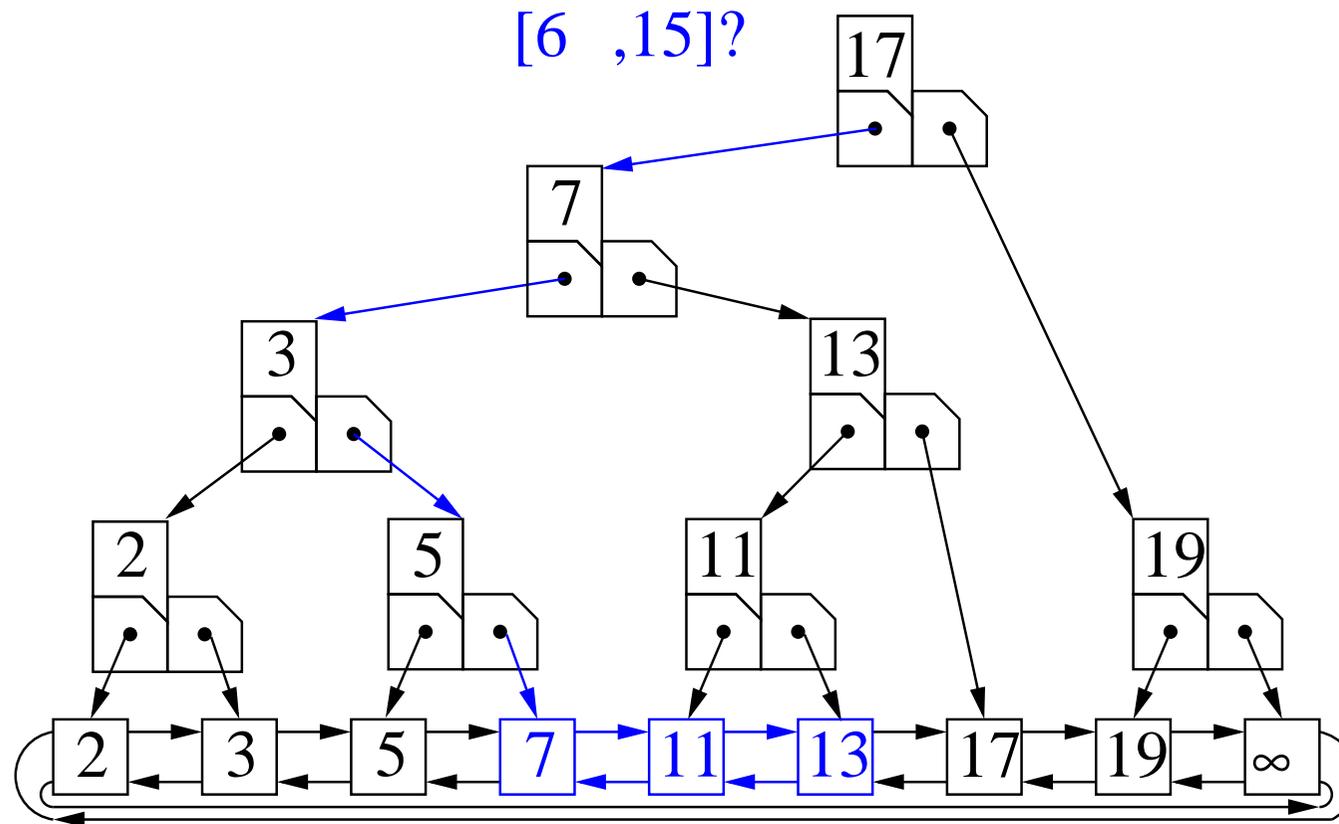
Anfragebearbeitung?

– Counting:  $O(\log n)$

– Reporting:  $O(k + \log n)$  oder wenigstens  $O(k \cdot \log n)$

# 1D Bereichssuche

Suchbaum



Zählanfragen: Teilbaumgrößen speichern

Sogar dynamisch !

## Reduktion auf $1..n \times 1..n$

vereinfachende Annahme: Koordinaten paarweise verschieden.

Ersetze Koordinaten  $P = \{(x_1, y_1), \dots, (x_n, y_n)\}$  durch ihren Rang:

$x_i \rightarrow$  Rang von  $x_i$  in  $\{x_1, \dots, x_n\}$

$y_i \rightarrow$  Rang von  $y_i$  in  $\{y_1, \dots, y_n\}$

## Reduktion auf $1..n \times 1..n$

Ersetze Koordinaten  $P = \{(x_1, y_1), \dots, (x_n, y_n)\}$  durch ihren Rang:

$P_x := \text{sort}(\langle x_1, \dots, x_n \rangle); \quad P_y := \text{sort}(\langle y_1, \dots, y_n \rangle)$

$P := \{(\text{binarySearch}(x, P_x), \text{binarySearch}(y, P_y)) : (x, y) \in P\}$

**Function** rangeQuery( $[x, x'] \times [y, y']$ )

$x := \text{binarySearchSucc}(x, P_x); \quad x' := \text{binarySearchPred}(x', P_x)$

$y := \text{binarySearchSucc}(y, P_y); \quad y' := \text{binarySearchPred}(y', P_y)$

$R := \text{intRangeQuery}([x, x'] \times [y, y'])$

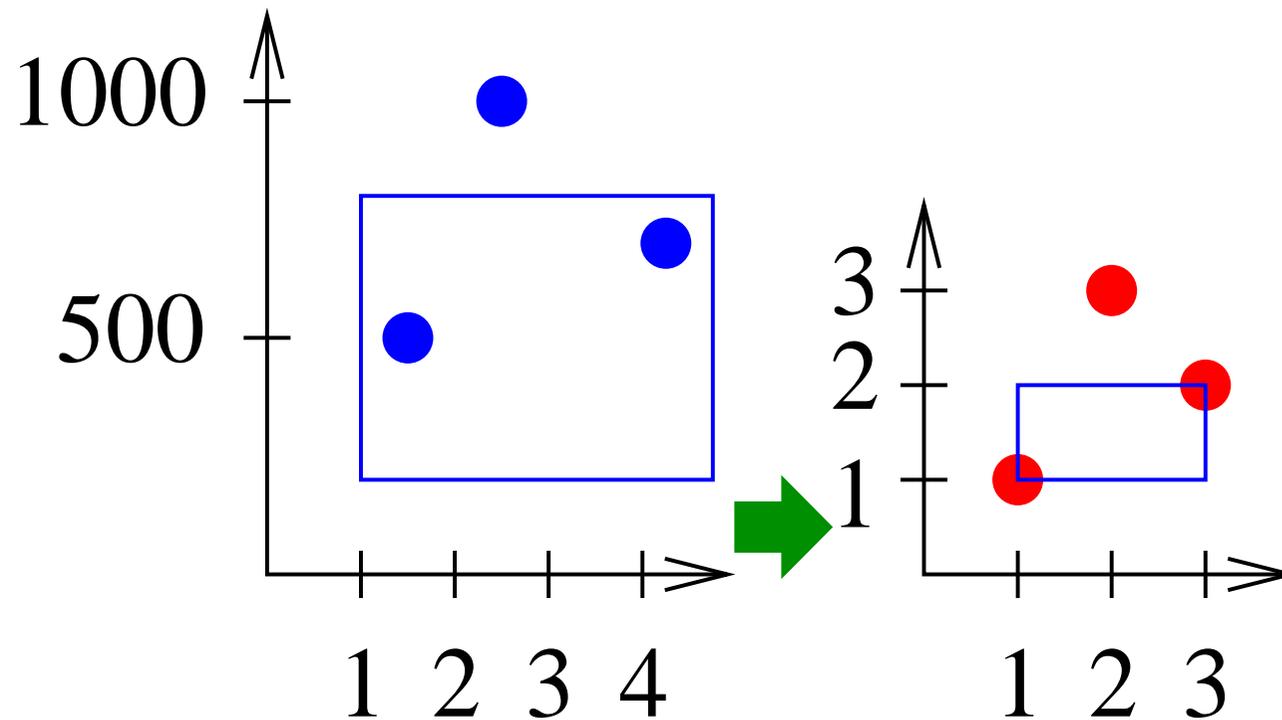
**return**  $\{(P_x[x], P_y[y]) : (x, y) \in R\}$

Konstruktionszeit  $O(n \log n)$ , Anfragezeit

$O(\log n) + T_{\text{intRangeQuery}}(n)$

# Beispiel

$$\{(2.5, 1000), (1.4, 500), (4.2, 700)\} \rightarrow \{(2, 3), (1, 1), (3, 2)\}$$



# Wavelet Tree

[Chazelle 1988, Grossi/Gupta/Vitter 2003, Mäkinen/Navarro 2007]

**Class** WaveletTree( $X = \langle x_1, \dots, x_n \rangle$ ) // represents  $(x_1, 1), \dots, (x_n, n)$

// Constructor:

**if**  $n < n_0$  **then** store  $X$  directly

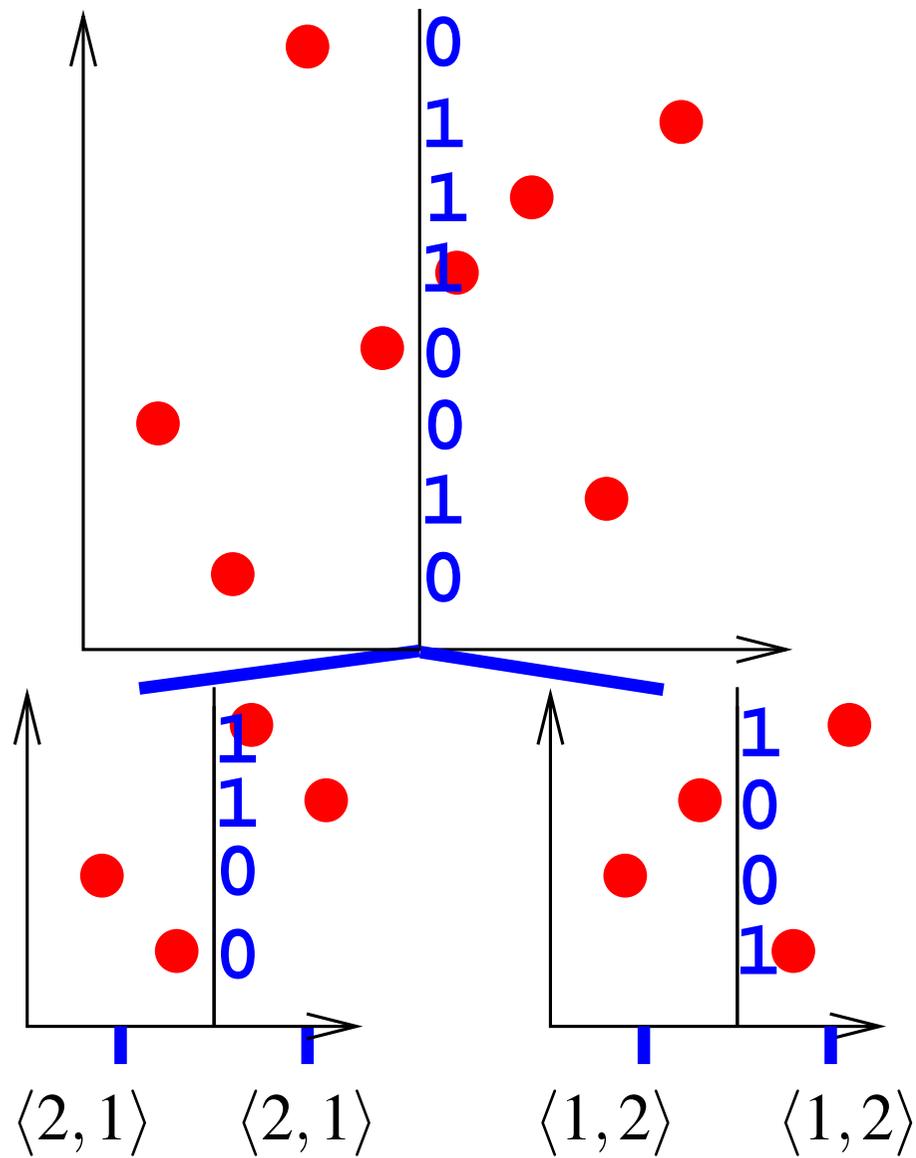
**else**

store bitvector  $b$  with  $b[i] = 1$  iff  $x_i > \lfloor n/2 \rfloor$

$\ell :=$  WaveletTree( $\langle x_i : x_i \leq \lfloor n/2 \rfloor \rangle$ )

$r :=$  WaveletTree( $\langle x_i - \lfloor n/2 \rfloor : x_i > \lfloor n/2 \rfloor \rangle$ )

# Beispiel

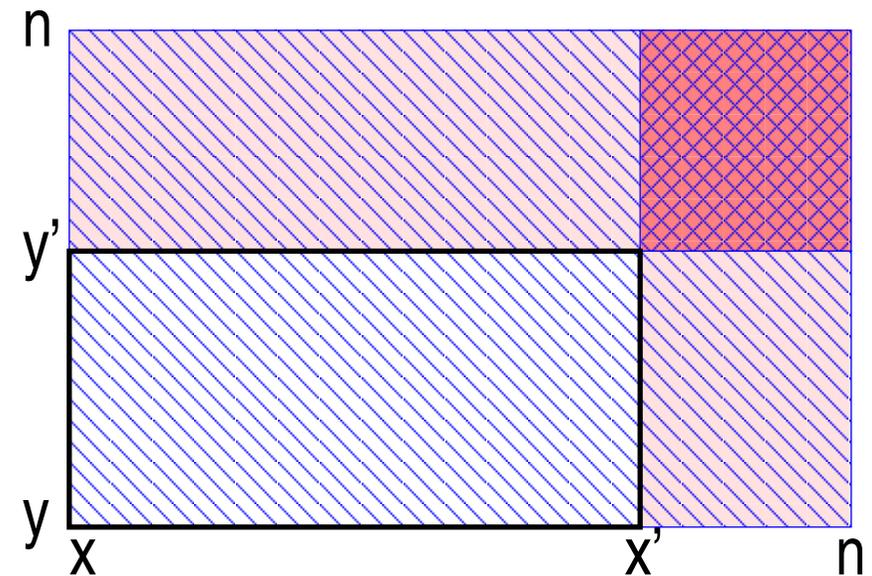


# Wavelet Tree Counting Query

**Function** `intRangeCount` ( $[x, x'] \times [y, y']$ )

**return**

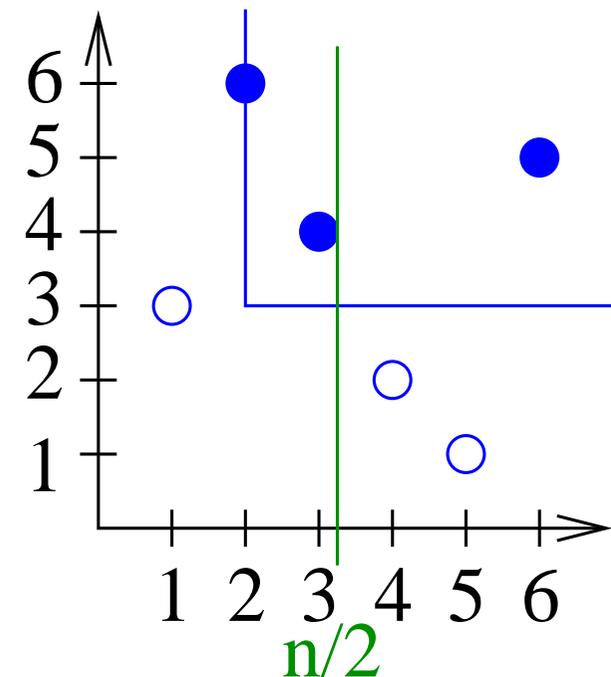
`intDominanceCount`( $x, y$ ) -  
`intDominanceCount`( $x', y$ ) -  
`intDominanceCount`( $x, y'$ ) +  
`intDominanceCount`( $x', y'$ )



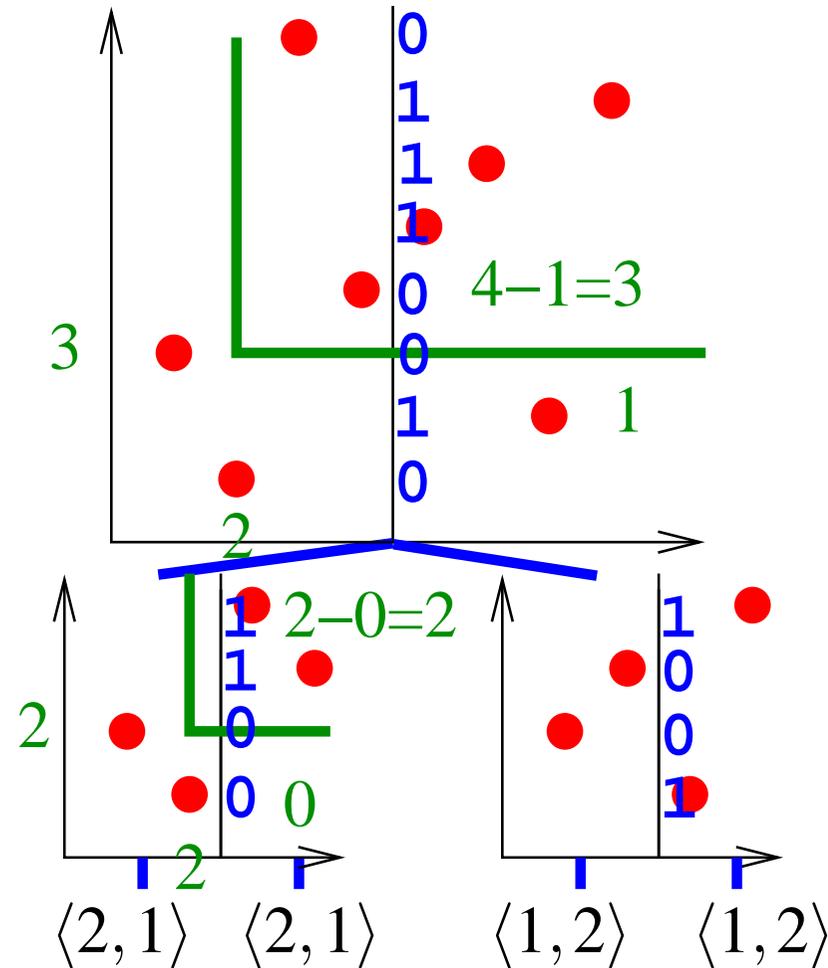
# Wavelet Tree Dominance Counting Query

```

Function intDominanceCount( $x, y$ )           //  $|[x, n] \times [y, n] \cap P|$ 
  if  $n \leq n_0$  then return  $|[x, n] \times [y, n] \cap P|$            // brute force
   $y_r := b.\text{rank}(y)$            // Number of els  $\leq y$  in right half
  if  $x \leq \lfloor n/2 \rfloor$  then
    return  $\ell.\text{intDominanceCount}(x, y - y_r) + \lceil n/2 \rceil - y_r$ 
  else
    return  $r.\text{intDominanceCount}(x - \lfloor n/2 \rfloor, y_r)$ 
  
```



# Beispiel



# Analyse

Nur ein rekursiver Aufruf.

Rekursionstiefe  $O(\log n)$ .

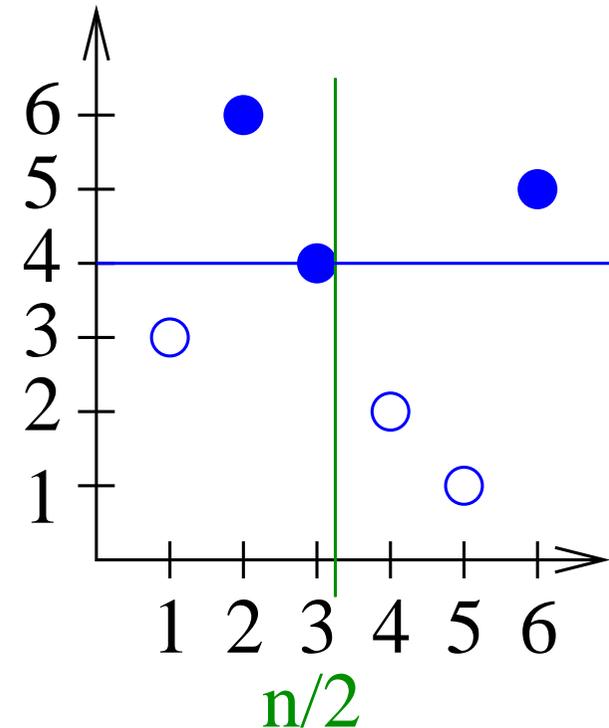
rank in konstanter Zeit (s.u.)

Zeit  $O(\log n)$

# Wavelet Tree Dominance Reporting Query

```
Function intDominanceReporting( $x, y$ )           //  $[x, n] \times [y, n] \cap P$   
  if  $n \leq n_0$  then return  $[x, n] \times [y, n] \cap P$            // brute force  
   $R := \emptyset$                                            // Result  
   $y_r := b.\text{rank}(y)$                                      // Number of els  $\leq y$  in right half  
  if  $x \leq \lfloor n/2 \rfloor$  then                             // Both halves interesting  
    if  $y - y_r < \frac{n}{2}$  then  $R := R \cup \ell.\text{intDominanceReporting}(x, y - y_r)$   
    if  $y_r < \frac{n}{2}$  then  $R := R \cup r.\text{oneSidedReporting}(y_r)$   
  else if  $y_r < \frac{n}{2}$  then  $R := R \cup r.\text{intDominanceReporting}(x - \lfloor n/2 \rfloor, y_r)$   
  return  $R$ 
```

**Function** oneSidedReporting( $y$ ) //  $[1, n] \times [y, n] \cap P$   
**if**  $n \leq n_0$  **then return**  $[1, n] \times [y, n] \cap P$  // brute force  
 $y_r := b.\text{rank}(y)$  // Number of els  $\leq y$  in right half  
 $R := \emptyset$   
**if**  $y_r < \frac{n}{2}$  **then**  $R := R \cup r.\text{oneSidedReporting}(y_r)$   
**if**  $y - y_r < \frac{n}{2}$  **then**  $R := R \cup \ell.\text{oneSidedReporting}(y - y_r)$   
**return**  $R$



# Analyse

Rekurrenz

$$T(n_0, 0) = O(1)$$

$$T(n, 0) = T(n/2, 0) + O(1) \implies T(n, 0) = O(\log n)$$

$$T(n, k) = T(n/2, k') + T(n/2, k - k') + O(1) \text{ also}$$

$$T(n, k) \leq ck' \log n + c(k - k') \log n + c = c(1 + k \log n) = O(k \log n)$$

Zeit  $O(k + \log n)$  braucht zusätzlichen Faktor  $\log n$  Platz.

Z.B. komplette Listen auf allen Ebenen speichern

Übungsaufgabe?

# Allgemeine Reporting Query

4-seitig

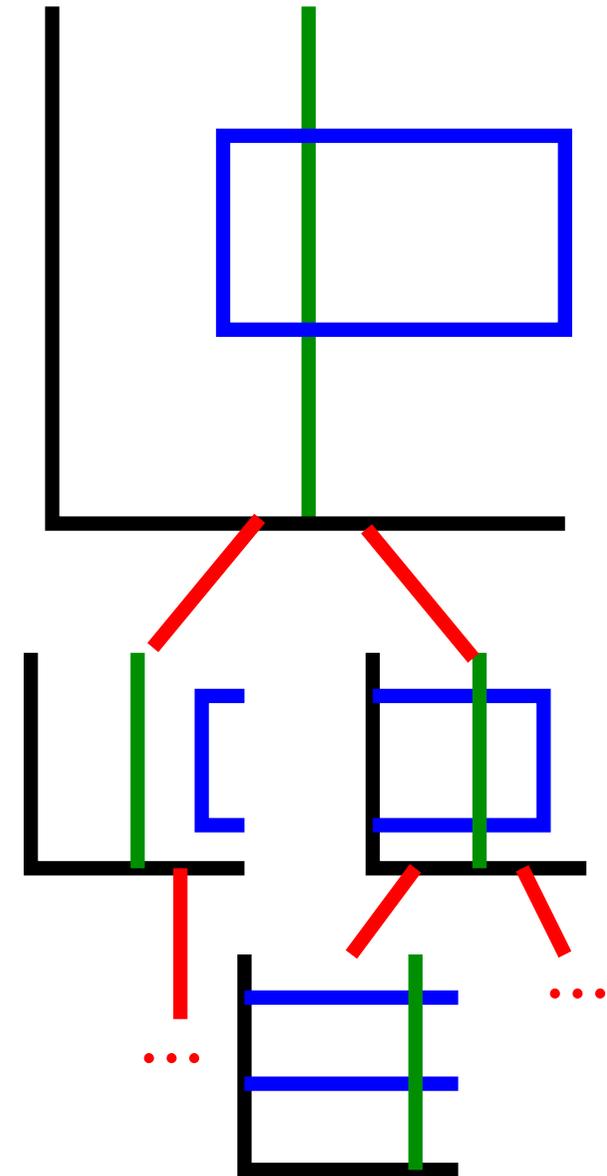


3-seitig (2 Varianten)



y-range

Analog oneSidedReporting (zwei Ranks statt einem)



# Bitvektoren $v$ mit rank in $O(1)$

Wähle  $B = \Theta(\log n)$ .

Vorberechnung  $\text{bRank}[i] := v.\text{rank}(iB)$

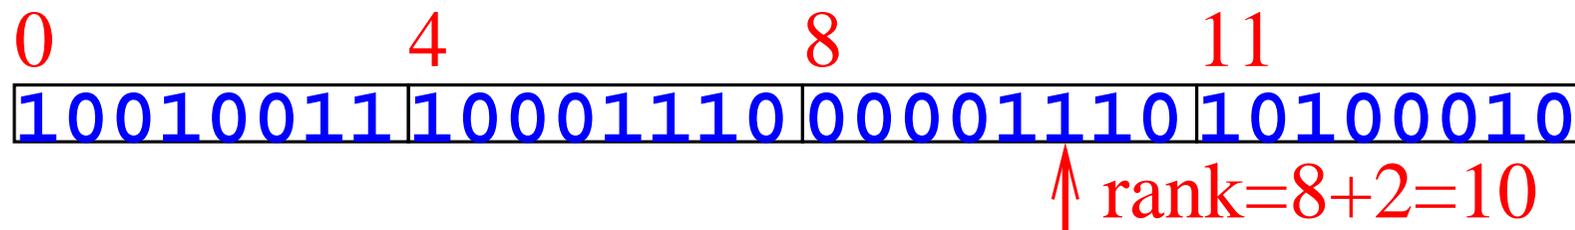
Zeit  $O(n)$ , Platz  $O(n)$  bits

Reduktion auf logarithmische Eingabegröße:

**Function**  $\text{rank}(j)$     **return**  $\text{bRank}[j \text{ div } B] + \text{rank}(v[B(j \text{ div } B)..j])$

Logarithmische Größe:

Maschinenbefehl (population count) oder Tabellenzugriff (z.B. Größe  $\sqrt{n}$  Zahlen)



## Mehr zu Bitvektoren

- weitere wichtige Operation  $b.select(i) :=$  Position des  $i$ -ten 1-bits.  
Ebenfalls  $O(1)$
- Informationstheoretisch asympt. optimaler Platz  $n + o(n)$  bits  
möglich.
- Grundlage für weitere **succinct data structures**
- Beispiel: **Baum** mit Platz  $2n + o(n)$  bits und Navigation in  
konstanter Zeit.

# 13 Onlinealgorithmen

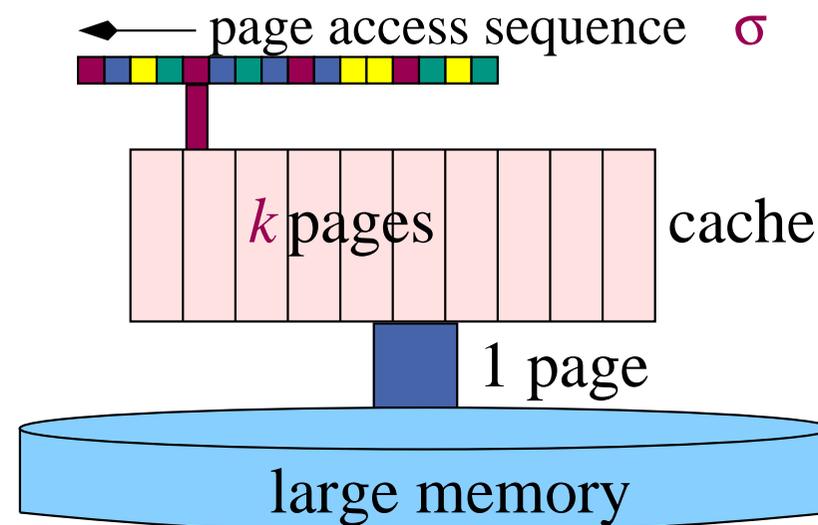
[z.T. von Rob van Stee]

- Information is revealed to the algorithm **in parts**
- Algorithm needs to process each part **before** receiving the next
- There is **no information** about the future  
(in particular, no probabilistic assumptions!)
- How well can an algorithm do  
compared to an algorithm that **knows everything**?
- Lack of **knowledge** vs. lack of **processing power**



# Examples

- Renting Skis etc.
- Paging** in a virtual memory system
- Routing** in communication networks
- Scheduling** machines in a factory, where orders arrive over time
- Google **placing** advertisements



# Competitive analysis

- Idea: compare online algorithm ALG to offline algorithm OPT
- Worst-case performance measure
- Definition:

$$C_{ALG} = \sup_{\sigma} \frac{ALG(\sigma)}{OPT(\sigma)}$$

(we look for the input that results in worst **relative** performance)

- Goal:  
find ALG with **minimal**  $C_{ALG}$

## A typical online problem: ski rental

- Renting skis costs 50 euros, buying them costs 300 euros
- You do not know in advance how often you will go skiing
- Should you rent skis or buy them?



## A typical online problem: ski rental

- Renting skis costs 50 euros, buying them costs 300 euros
- You do not know in advance how often you will go skiing
- Should you rent skis or buy them?
- Suggested algorithm: buy skis on the sixth trip
- Two questions:
  - How good is this algorithm?
  - Can you do better?



## Upper bound for ski rental

- You plan to buy skis on the sixth trip
- If you make five trips or less, you pay **optimal** cost (50 euros per trip)
- If you make at least six trips, you pay 550 euros
- In this case OPT pays at least 300 euros
- Conclusion: algorithm is  $\frac{11}{6}$ -competitive:  
it never pays more than  $\frac{11}{6}$  times the optimal cost

## Lower bound for ski rental

- Suppose you buy skis **earlier**, say on trip  $x < 6$ .  
You pay  $300 + 50(x - 1)$ , OPT pays only  $50x$

$$\frac{250 + 50x}{50x} = \frac{5}{x} + 1 \geq 2.$$

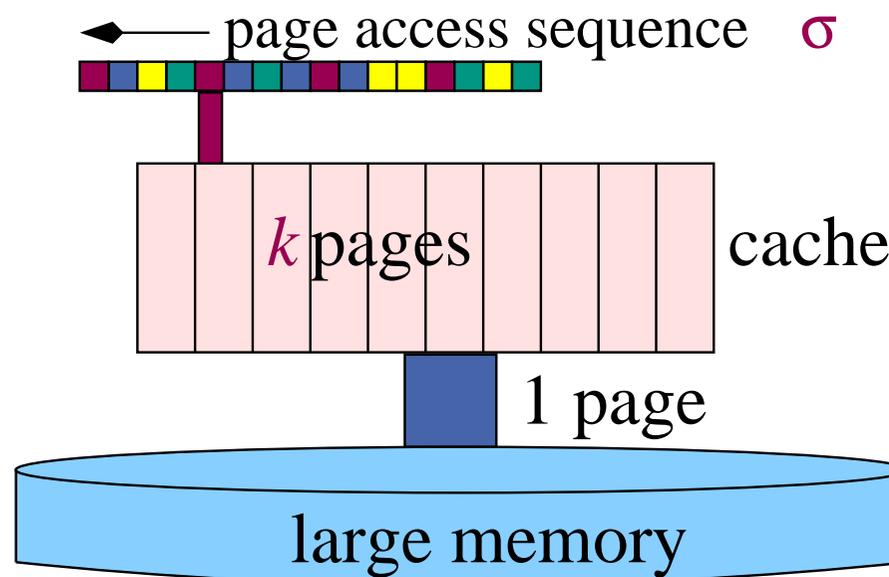
- Suppose you buy skis **later**, on trip  $y > 6$ .  
You pay  $300 + 50(y - 1)$ , OPT pays only 300

$$\frac{250 + 50y}{300} = \frac{5 + y}{6} \geq 2.$$

- Idea: do not pay the large cost (buy skis) until you would have paid **the same amount** in small costs (rent)

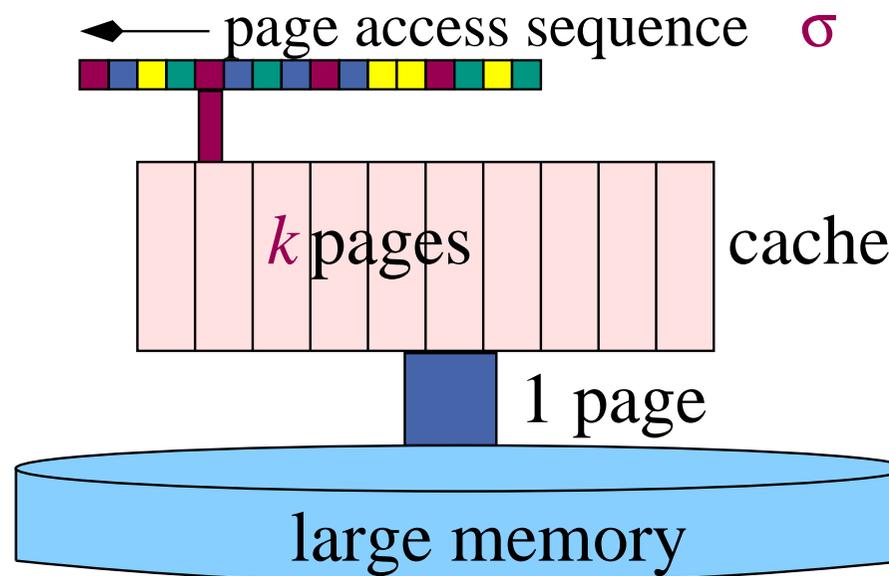
# Paging

- Computers usually have a small amount of fast memory (cache)
- This can be used to store data (pages) that are often used
- Problem when the cache is full and a new page is requested
- Which page should be thrown out (evicted)?



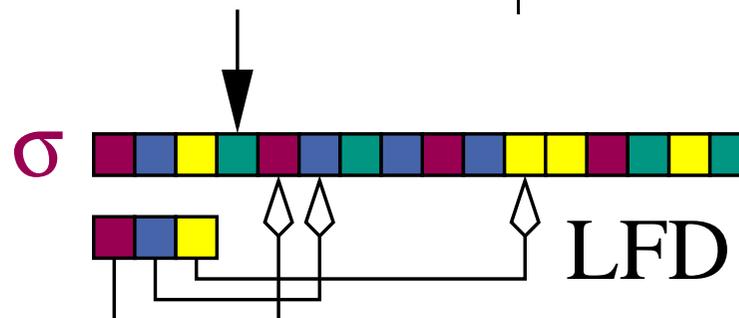
## Definitions

- $k$  = size of cache (number of pages)
- We assume that access to the cache is **free**, since accessing main memory costs much more
- Thus, a cache hit costs 0 and a miss (fault) costs 1
- The goal is to **minimize the number of page faults**



# Paging algorithms

algorithm		which page to <b>evict</b>
LIFO	Last In First Out	newest
FIFO	First In First Out	oldest
LFU	Least Frequently used	requested <b>least often</b>
LRU	Least Recently Used	requested <b>least recently</b>
FWF	Flush When Full	<b>all</b>
LFD	Longest Forward Distance	(re)requested <b>latest in the future</b>

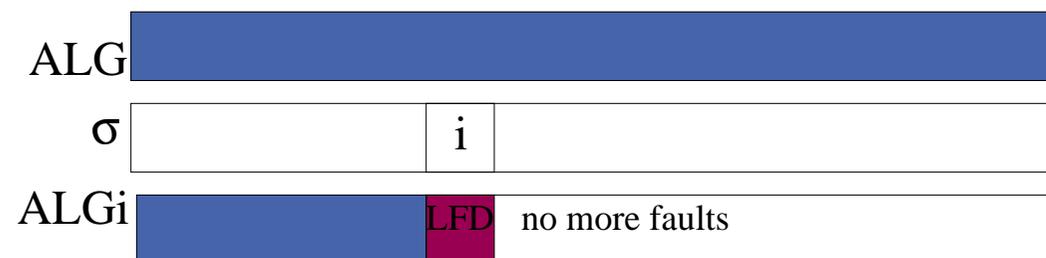


# Longest Forward Distance is optimal

We show: any optimal offline algorithm can be changed to **act like LFD** without increasing the number of page faults.

**Inductive claim:** given an algorithm ALG, we can create  $ALG_i$  such that

- ALG and  $ALG_i$  act **identically** on the first  $i - 1$  requests
- If request  $i$  causes a fault (for **both** algorithms),  $ALG_i$  evicts page with **longest forward distance**
- $ALG_i(\sigma) \leq ALG(\sigma)$

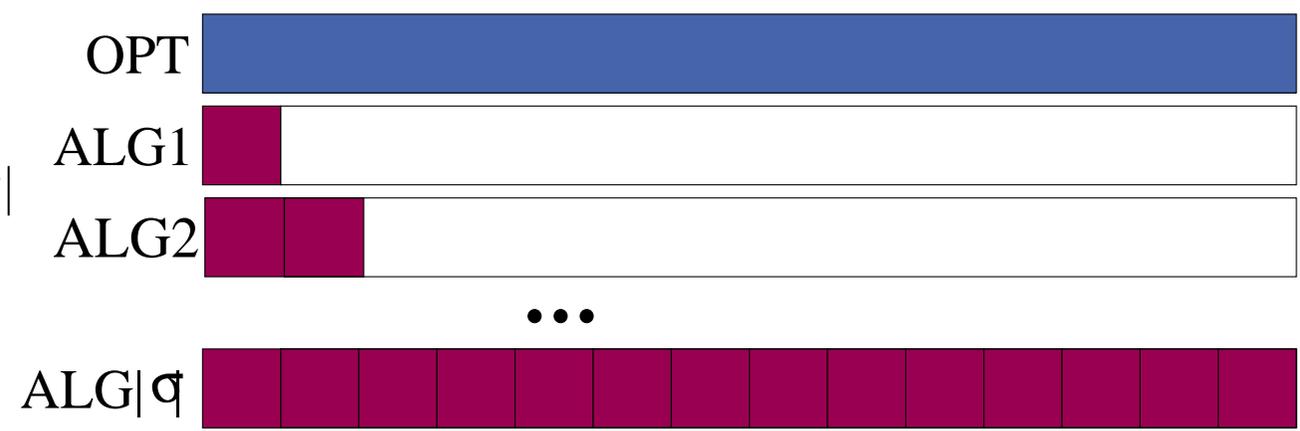


# Using the claim

- Start with a given request sequence  $\sigma$  and an optimal offline algorithm ALG
- Use the claim for  $i = 1$  on ALG to get  $ALG_1$ , which evicts the LFD page on the first request (if needed)
- Use the claim for  $i = 2$  on  $ALG_1$  to get  $ALG_2$

...

Final algorithm  $ALG_{|\sigma|}$  is equal to OPT



# **Proof of the claim**

not this time

## Comparison of algorithms

- OPT is not online, since it looks forward
- Which is the best online algorithm?
- LIFO is **not** competitive: consider an input sequence

$$p_1, p_2, \dots, p_{k-1}, p_k, p_{k+1}, p_k, p_{k+1}, \dots$$

- LFU is also **not** competitive: consider

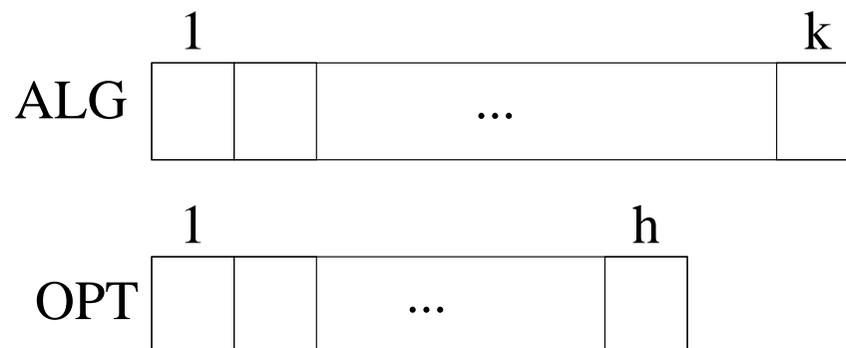
$$p_1^m, p_2^m, \dots, p_{k-1}^m, (p_k, p_{k+1})^{m-1}$$

## A general lower bound

- To illustrate the problem, we show a lower bound for **any** online paging algorithm ALG
- There are  $k + 1$  pages
- At all times, ALG has  $k$  pages in its cache
- There is always one page missing: request this page at each step
- OPT only faults **once every  $k$  steps**  
⇒ **lower bound of  $k$**  on the competitive ratio

## Resource augmentation

- We will compare an online algorithm ALG to an optimal offline algorithm **which has a smaller cache**
- We hope to get **more realistic** results in this way
- Size of offline cache =  $h < k$
- This problem is known as  $(h, k)$ -paging



# Conservative algorithms

- An algorithm is **conservative** if it has at most  $k$  page faults on any request sequence that contains at most  $k$  distinct pages
- The request sequence may be **arbitrarily long**
- LRU and FIFO are conservative
- LFU and LIFO are **not** conservative (recall that they are not competitive)

# Competitive ratio

**Theorem:** Any conservative algorithm is  $\frac{k}{k-h+1}$ -competitive

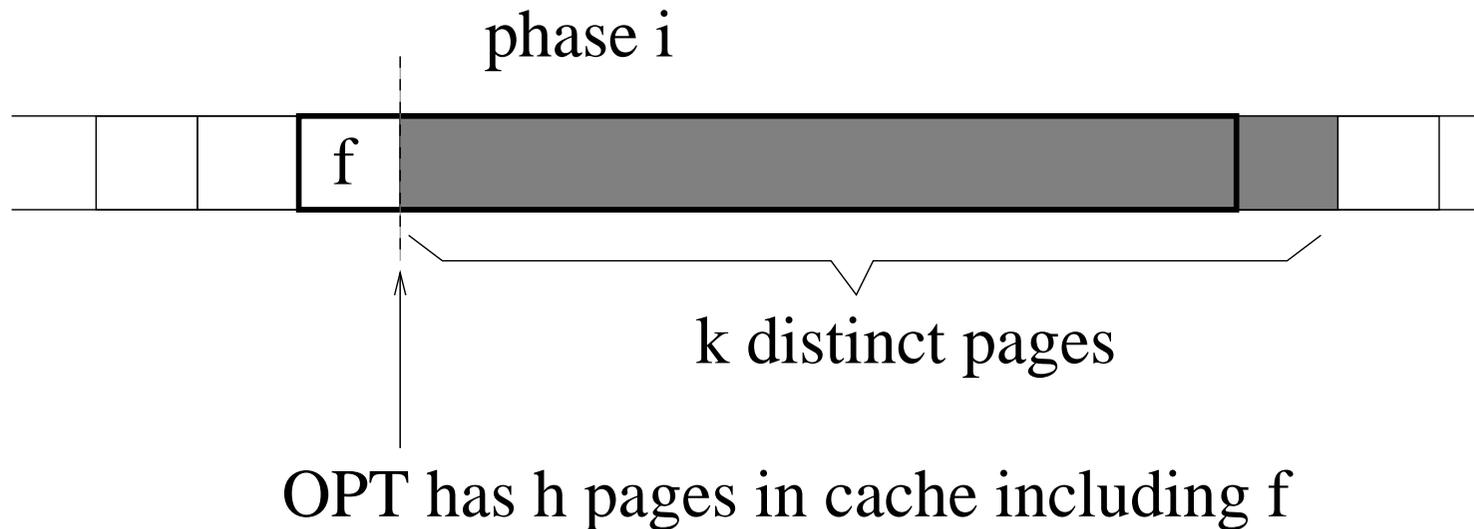
**Proof:** divide request sequence  $\sigma$  into **phases**.

- Phase 0 is the empty sequence
- Phase  $i > 0$  is the maximal sequence following phase  $i - 1$  that contains at most  $k$  distinct pages

Phase partitioning **does not depend on algorithm**. A conservative algorithm has at most  $k$  faults per phase.

## Counting the faults of OPT

Consider some phase  $i > 0$ , denote its first request by  $f$



Thus OPT has at least  $k - (h - 1) = k - h + 1$  faults on the grey requests

## Conclusion

- In each phase, a conservative algorithm has  $k$  faults
- To each phase except the last one, we can assign (charge)  $k - h + 1$  faults of OPT
- Thus

$$\text{ALG}(\sigma) \leq \frac{k}{k - h + 1} \cdot \text{OPT}(\sigma) + r$$

where  $r \leq k$  is the number of page faults of ALG in the last phase

- This proves the theorem

## Notes

- For  $h = k/2$ , we find that conservative algorithms are 2-competitive
- The previous lower bound construction does not work for  $h < k$
- In practice, the “competitive ratio” of LRU is a small constant
- Resource augmentation can give better (more realistic) results than pure competitive analysis

## New results (Panagiotou & Souza, STOC 2006)

- Restrict the adversary to get more “natural” input sequences
- Locality of reference**: most consecutive requests to pages have short distance
- Typical memory access patterns**: consecutive requests have either short or long distance compared to the cache size

## Randomized algorithms

- Another way to avoid the lower bound of  $k$  for paging is to use a **randomized** algorithm
- Such an algorithm is allowed to use random bits in its decision making
- Crucial is **what the adversary knows** about these random bits

## Three types of adversaries

- Oblivious**: knows only the probability distribution that ALG uses, determines input in advance
- Adaptive online**: knows random choices made so far, bases input on these choices
- Adaptive offline**: knows random choices in advance (!)

Randomization **does not help** against adaptive offline adversary

We focus on the **oblivious** adversary

# Marking Algorithm

- marks** pages which are requested
- never evicts a marked page**
- When **all** pages are marked **and there is a fault**, unmark everything  
(but mark the page which caused the fault)  
(new **phase**)

# Marking Algorithms

Only difference is eviction strategy

- LRU
- FWF
- RMARK: Evict an unmarked page chosen **uniformly at random**

# Competitive ratio of RMARK

**Theorem:** RMARK is  $2H_k$ -competitive

where

$$H_k = 1 + \frac{1}{2} + \frac{1}{3} + \cdots + \frac{1}{k} \leq \ln k + 1$$

is the  $k$ -th harmonic number

## Analysis of RMARK

Consider a phase with  $m$  new pages

(that are not cached in the beginning of the phase)

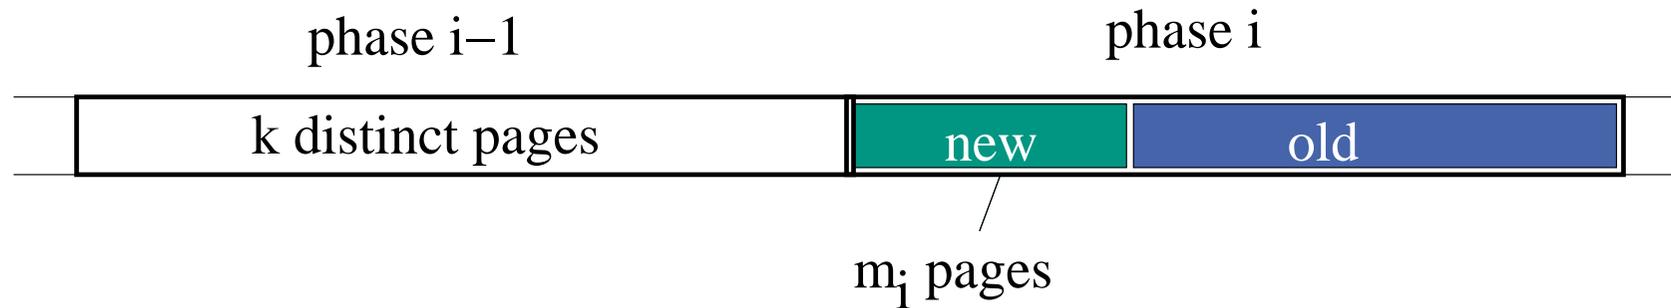
Miss probability when  $j + 1$ st old page becomes marked

$$1 - \frac{\text{\# old unmarked cached pages}}{\text{\# old unmarked pages}} \leq 1 - \frac{k - m - j}{k - j} = \frac{m}{k - j}$$

Overall expected number of faults (including new pages):

$$m + \sum_{j=0}^{k-m-1} \frac{m}{k-j} = m + m \sum_{i=m+1}^k \frac{1}{i} = m(1 + H_k - H_m) \leq mH_k$$

## Lower bound for OPT



- There are  $m_i$  new pages in phase  $i$
- Thus, in phases  $i-1$  and  $i$  together,  $k + m_i$  pages are requested
- OPT makes at least  $m_i$  faults in phases  $i$  and  $i-1$  for any  $i$
- Total number of OPT faults is at least  $\frac{1}{2} \sum_i m_i$

## Upper bound for RMARK

- Expected number of faults in phase  $i$  is at most  $m_i H_k$  for RMARK
- Total expected number of faults is at most  $H_k \sum_i m_i$
- OPT has at least  $\frac{1}{2} \sum_i m_i$  faults
- Conclusion: RMARK is  $2H_k$ -competitive

## Randomized lower bound

**Theorem:** No randomized can be better than  $H_k$ -competetive against an oblivious adversary.

**Proof:** not here

## Discussion

- $H_k \ll k$
- The upper bound for RMARK holds against an oblivious adversary  
(the input sequence is **fixed in advance**)
- No algorithm can be better than  $H_k$ -competitive
- Thus, RMARK is optimal apart from a factor of 2
- There is a (more complicated) algorithm that is  $H_k$  competitive

## Why **competitive analysis**?

There are many models for “decision making in the absence of complete information”

- Competitive analysis leads to algorithms that would not otherwise be considered
- Probability distributions are rarely known precisely
- Assumptions about distributions must often be unrealistically crude to allow for mathematical tractability
- Competitive analysis gives a **guarantee** on the performance of an algorithm, which is essential in e.g. financial planning

## **Disadvantages of competitive analysis**

- Results can be too pessimistic (adversary is too powerful)
  - Resource augmentation
  - Randomization
  - Restrictions on the input
  
- Unable to distinguish between some algorithms that perform differently in practice
  - Paging: LRU and FIFO
  - more refined models