

# Algorithmen II

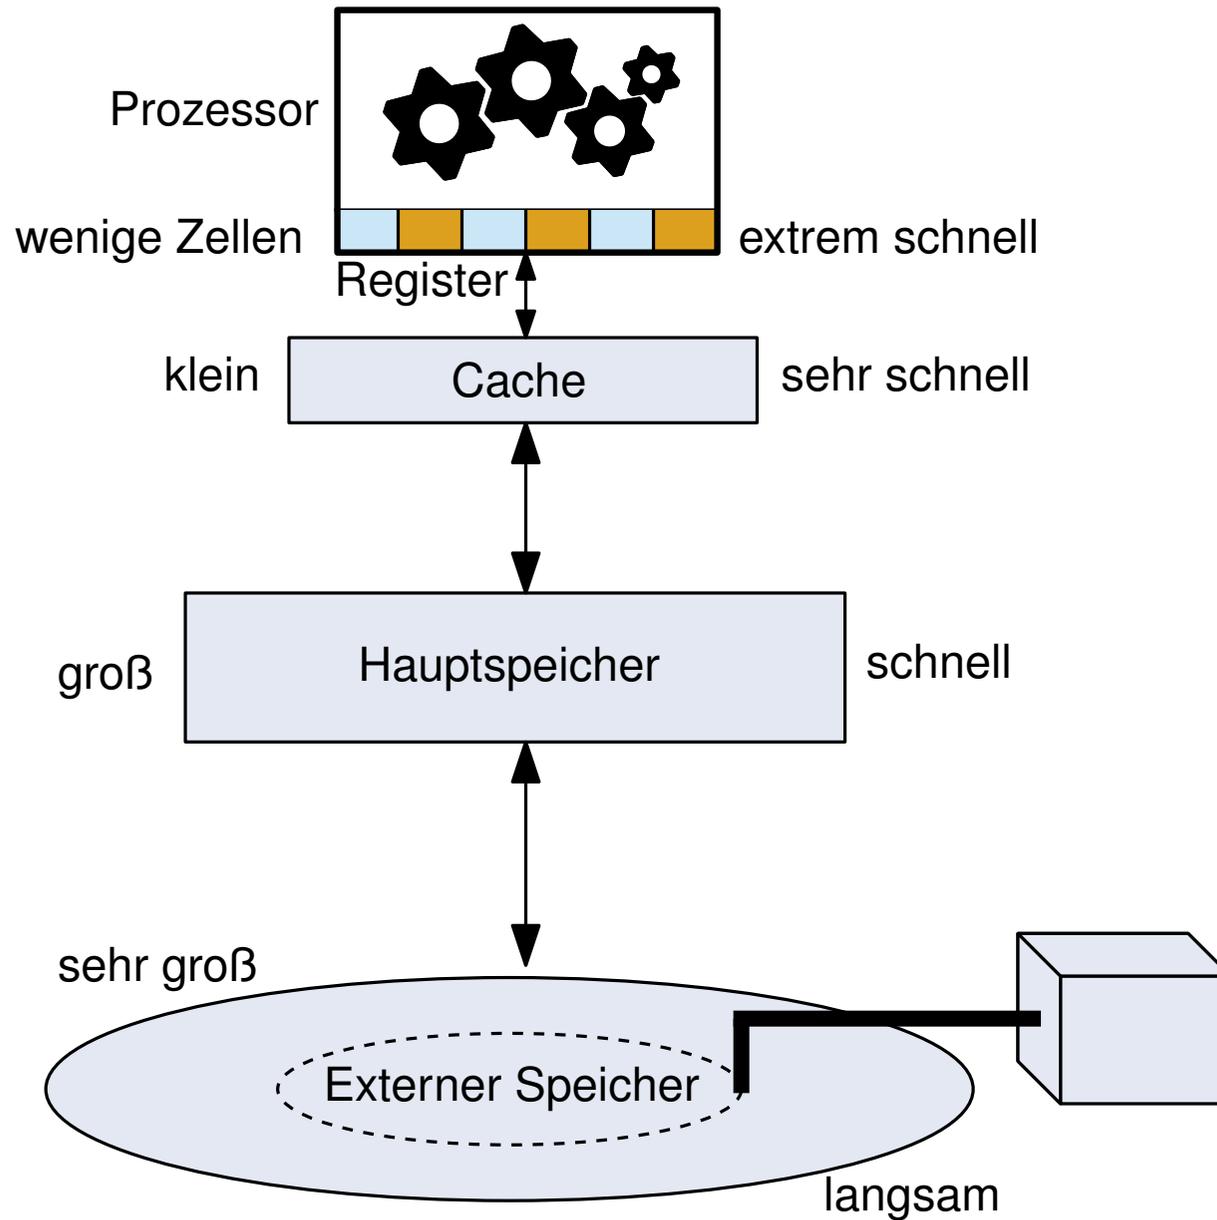
## Vorlesung am 31.01.2013

Algorithmen für externen Speicher

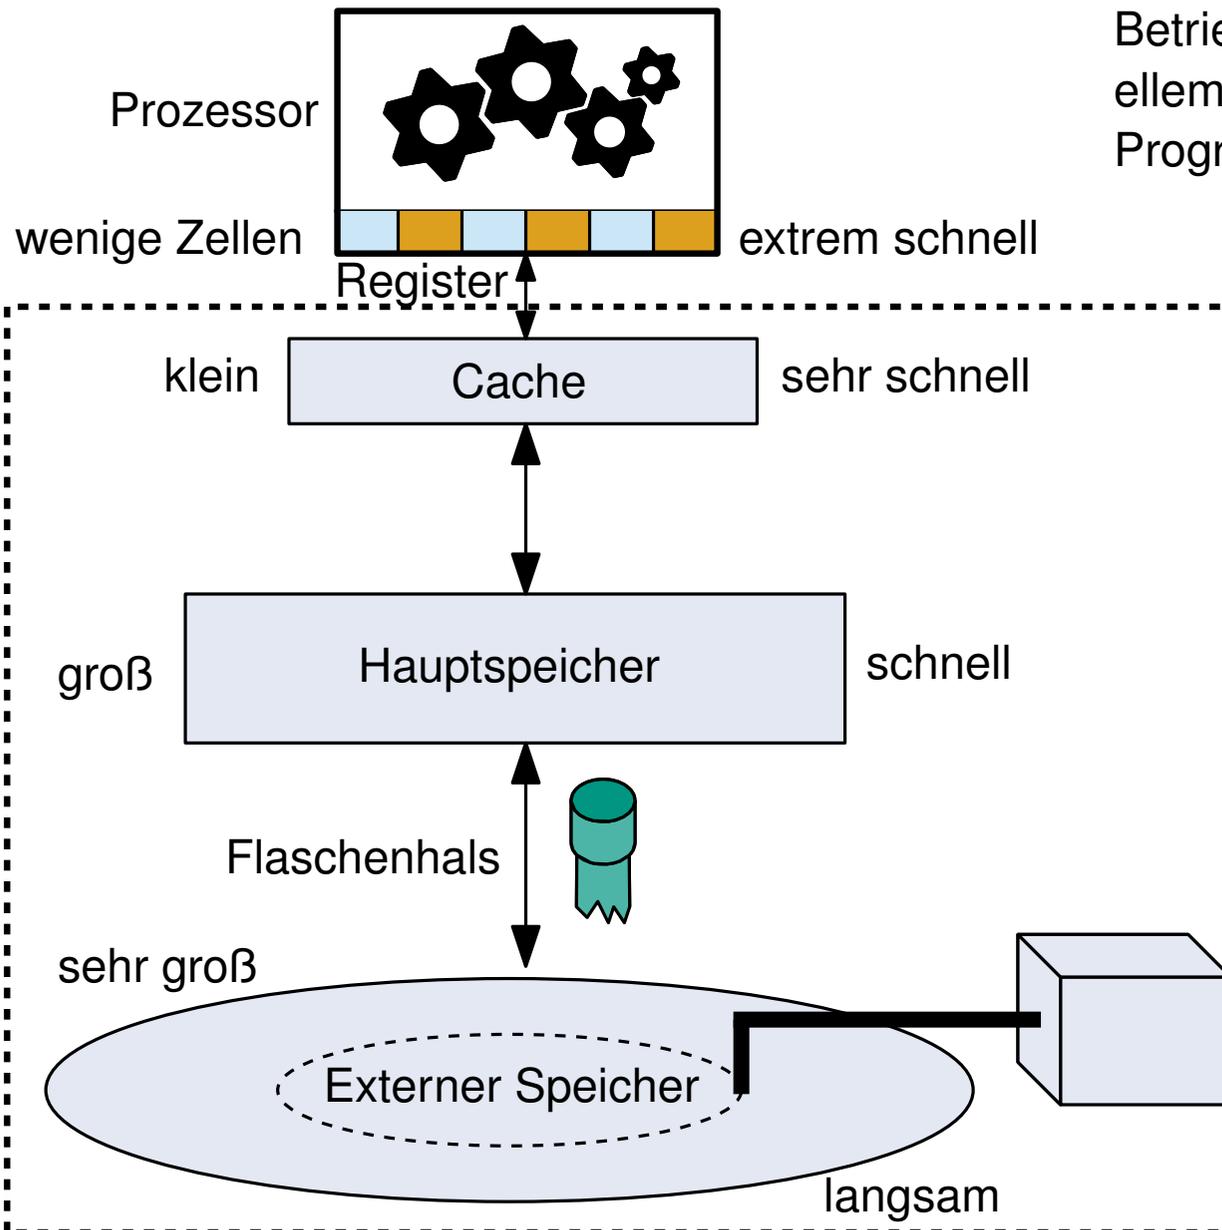
INSTITUT FÜR THEORETISCHE INFORMATIK · PROF. DR. DOROTHEA WAGNER



# Einfaches Rechnermodell



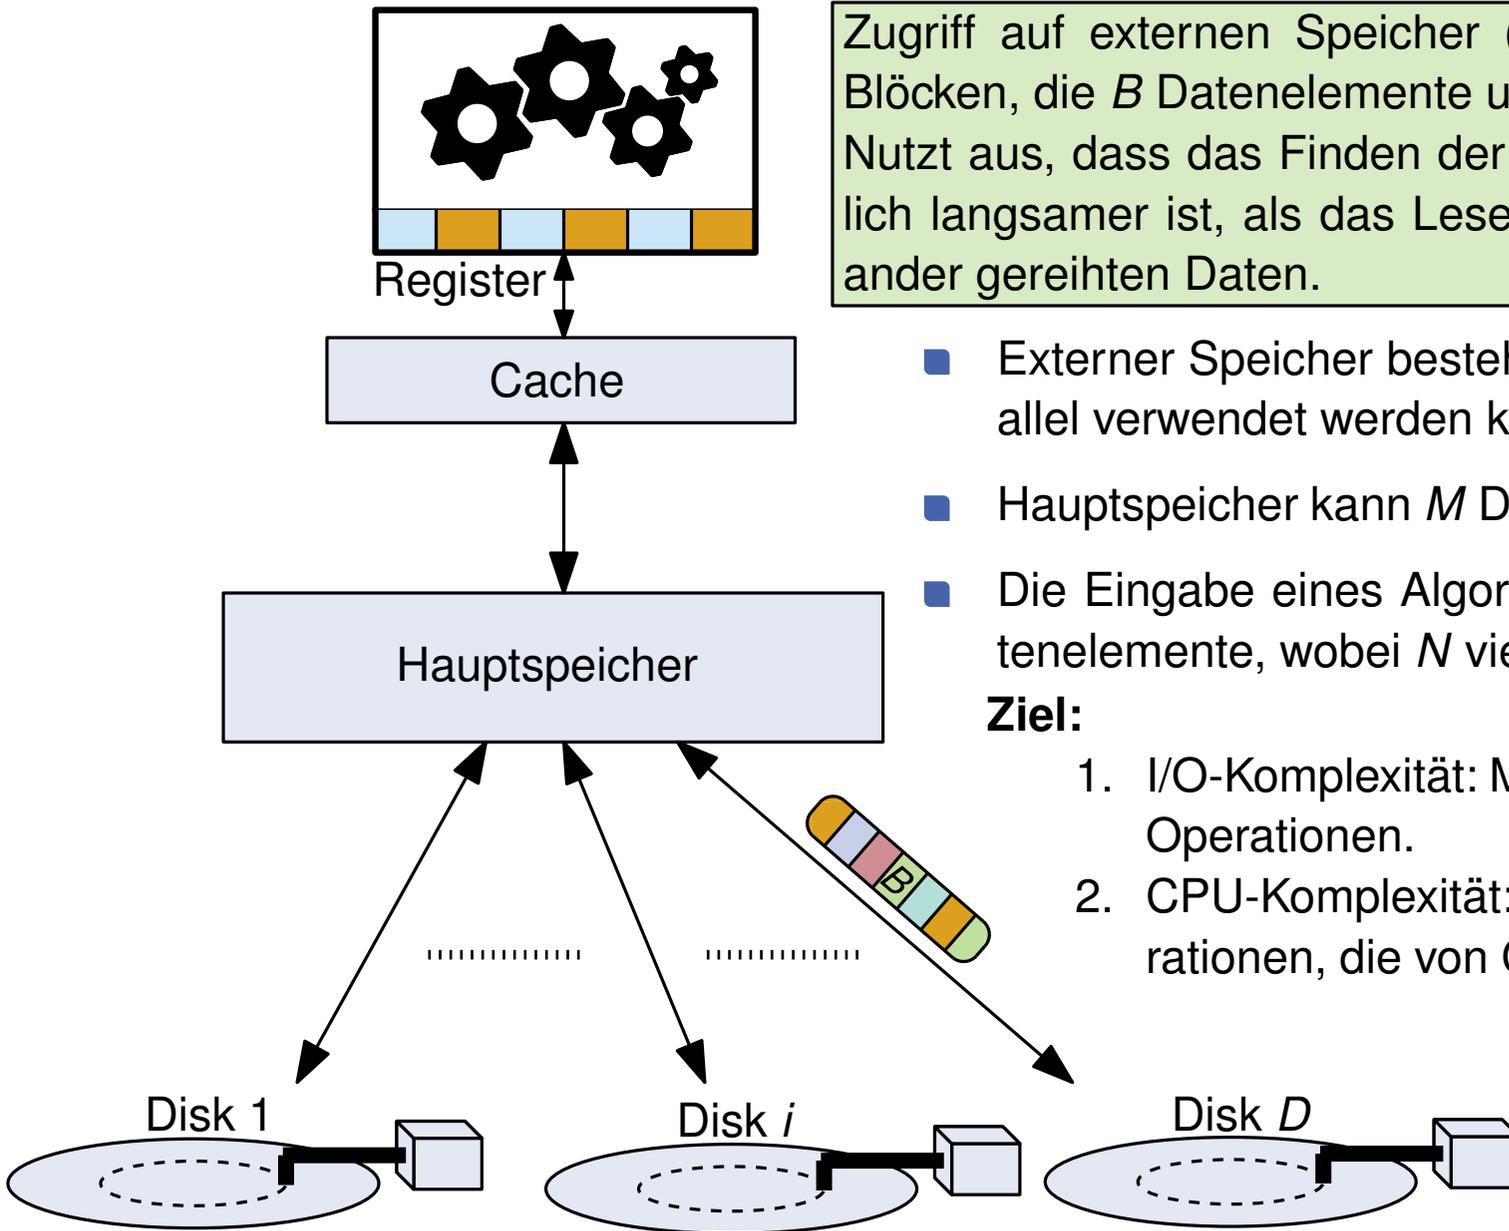
# Einfaches Rechnermodell



Betriebssystem bildet mithilfe von virtuellem Speicher eine Abstraktionsebene: Programm *sieht* nur einen Speicher.

**Problem:** Wenn auf großen Datenmengen gearbeitet wird, dann muss Betriebssystem viele Daten zwischen Hauptspeicher und externem Speicher transportieren, um virtuellen Speicher zu simulieren.

**Deshalb:** Manchmal besser nicht die Abstraktion zu verwenden.



Zugriff auf externen Speicher (I/O) passiert immer in Blöcken, die  $B$  Datenelemente umfassen:  
Nutzt aus, dass das Finden der richtigen Position deutlich langsamer ist, als das Lesen/Schreiben von aneinander gereihten Daten.

- Externer Speicher besteht aus  $D$  Platten, die parallel verwendet werden können.
- Hauptspeicher kann  $M$  Datenelemente speichern.
- Die Eingabe eines Algorithmus hat Größe  $N$  Datenelemente, wobei  $N$  viel größer ist als  $M$ .

### Ziel:

1. I/O-Komplexität: Minimiere Anzahl der I/O-Operationen.
2. CPU-Komplexität: Minimiere Anzahl Operationen, die von CPU ausgeführt werden.

# Grundprinzipien:

Grundprinzipien, die beim Design von Algorithmen auf externem Speicher eingehalten werden sollten:

- **Interne Effizienz:** Die interne Arbeit, die vom Algorithmus durchgeführt wird, sollte mit der vergleichbar sein, die von den besten Algorithmen mit internem Speicher geleistet wird.
- **Räumliche Lokalität:** Wenn auf ein Block  $B$  im externen Speicher zugegriffen wird, dann sollte dieser möglichst viel nützliche Information enthalten.
- **Zeitliche Lokalität:** Sobald Daten im internen Speicher (Hauptspeicher) sind, dann sollte möglichst viel nützliche Arbeit auf diesen Daten ausgeführt werden, bevor sie in den externen Speicher zurückgeschrieben werden.

Zugriff auf externen Speicher ist teuer!

Viele Algorithmen mit externem Speicher verwenden die Grundoperationen *Scannen*, und *Sortieren*:

**Scannen:** Anstatt jedes Datenelement einzeln aus dem externen Speicher zu laden, sollte dies in Blöcken geschehen. Das Laden von  $N$  Datenelementen aus dem externen Speicher sollte im optimalen Fall  $\text{scan}(N) := \Theta\left(\frac{N}{D \cdot B}\right)$  I/Os kosten.

**Sortieren:** Externes Sortieren von  $N$  Elementen ist mit  $\text{sort}(N) := \Theta\left(\frac{N}{D \cdot B} \cdot \log_{\frac{M}{B}} \frac{N}{B}\right)$  I/Os möglich. Sinnvoll, wenn Daten nicht so vorliegen, dass externer Scann möglich ist (siehe spätere Folien).

## Notation:

- $M$ : Größe des Hauptspeichers.
- $N$ : Größe der Instanz:
- $D$ : Anzahl der Platten des externen Speichers.
- $B$ : Anzahl Elemente in einem Block.

# Interner Stack

Interner Stack (arbeitet nur auf Hauptspeicher), der maximal  $m$  Elemente enthält, kann mithilfe eines Arrays  $S$  der Größe  $m$  und einem Zähler  $top$  implementiert werden. Hierzu initialisiere  $top$  mit  $-1$ .

Operation  $push(e)$ :  
Effekt: Legt Element  $e$  auf den Stack.

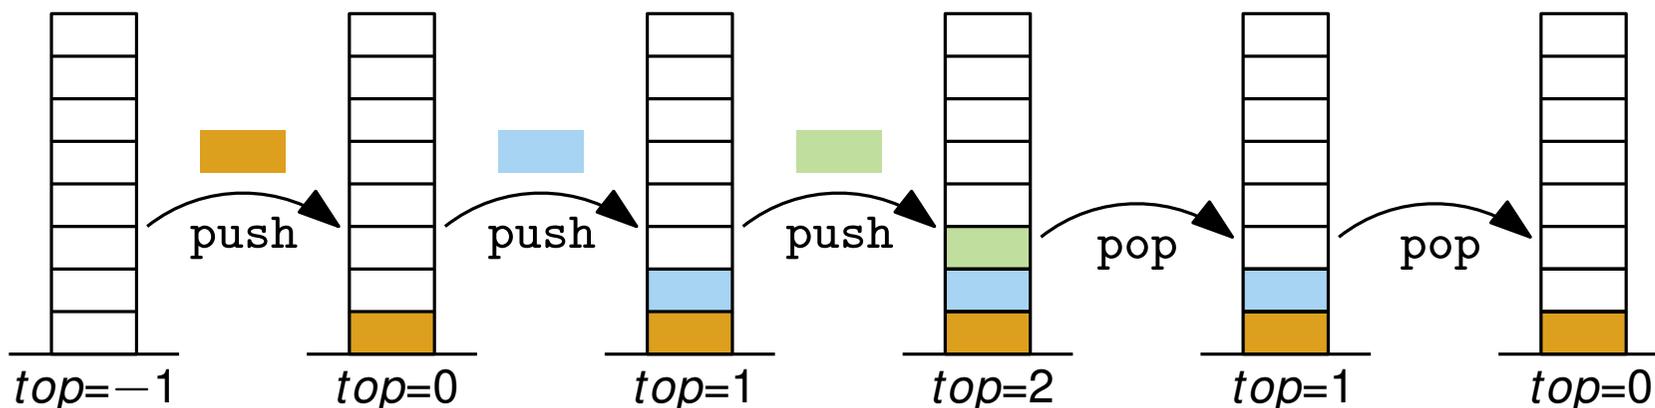
```
wenn  $top < m - 1$  dann  
   $top \leftarrow top + 1$   
   $S[top] \leftarrow e$ 
```

Operation  $pop()$ :  
Effekt: Entfernt das oberste Element vom Stack.

```
wenn  $top = -1$  dann return  $nil$   
 $temp \leftarrow S[top]$   
 $top \leftarrow top - 1$   
return  $temp$ 
```

Operation  $clear()$ :  
Effekt: Löscht alle Elemente vom Stack.

```
 $top \leftarrow -1$ 
```



# Externer Stack

Kann mithilfe eines internen Stacks  $S$  der Größe  $2 \cdot B$  umgesetzt werden:

Operation `externalPush( $e$ )`:  
Effekt: Legt  $e$  auf externen Stack.

**wenn  $S$  voll dann**  
Kopiere  $S$  in externen Speicher.  
`S.clear()`.  
`S.push( $e$ )`

Operation `externalPop()`:  
Effekt: Entfernt das oberste Element vom externen Stack.

**wenn  $S$  leer dann**  
Kopiere die  $B$  zuletzt geschriebenen Elemente aus dem externen Speicher in  $S$ .  
`S.pop()`

## Analyse:

1. I/Os treten nur auf, wenn Puffer im Hauptspeicher leer oder voll ist.
2. Amortisiert ergibt sich damit  $O(\frac{1}{B})$  I/Os pro Operation.
3. Nicht besser möglich: Pro I/O können maximal  $B$  Elemente gelesen oder geschrieben werden.



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

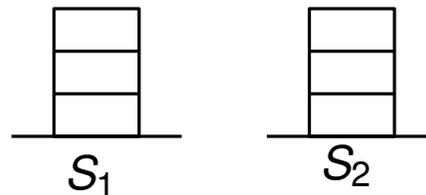
**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

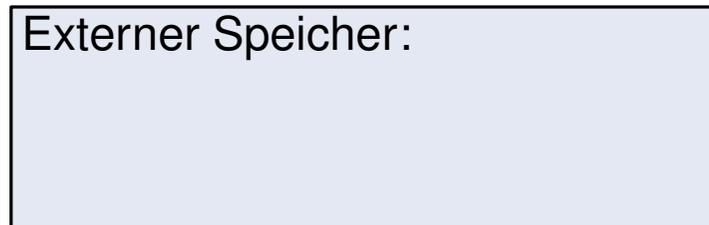
`$S_1$ .clear()`

`$S_2$ .pop()`

→ add   
 add   
 add   
 remove  
 remove  
 remove  
 add   
 add   
 add   
 add   
 remove



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

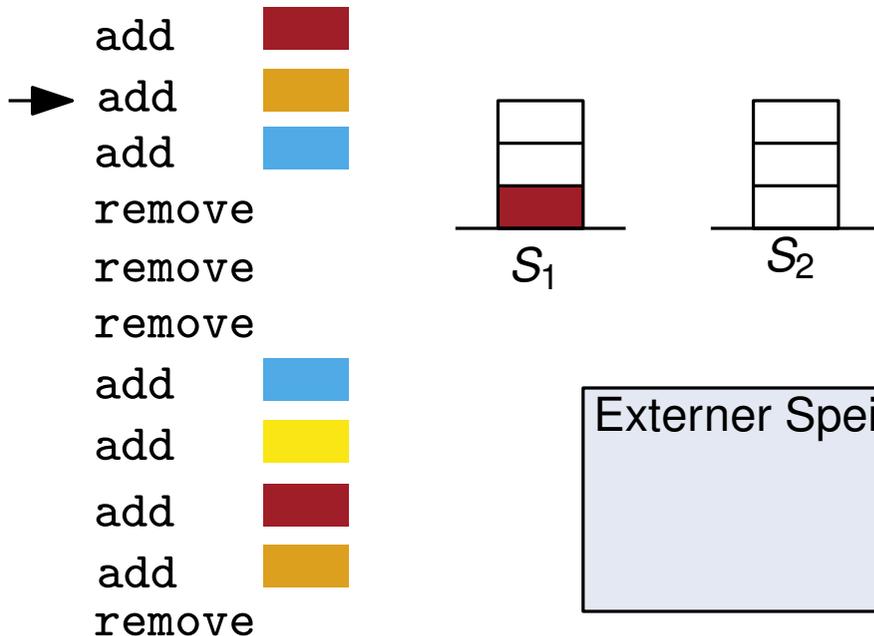
Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add(e)`:

Effekt: Hängt *e* an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push(e)`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

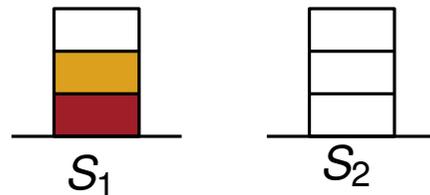
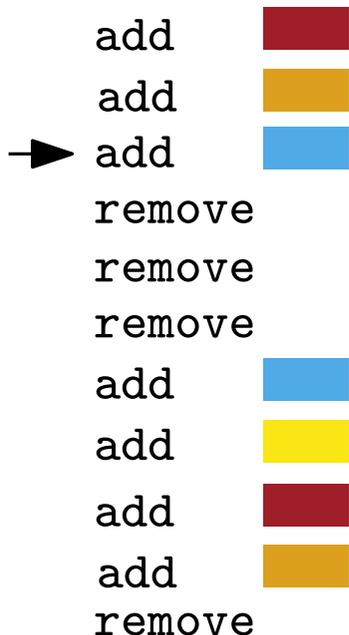
Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

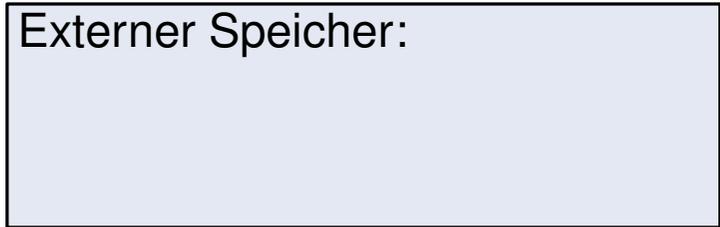
Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

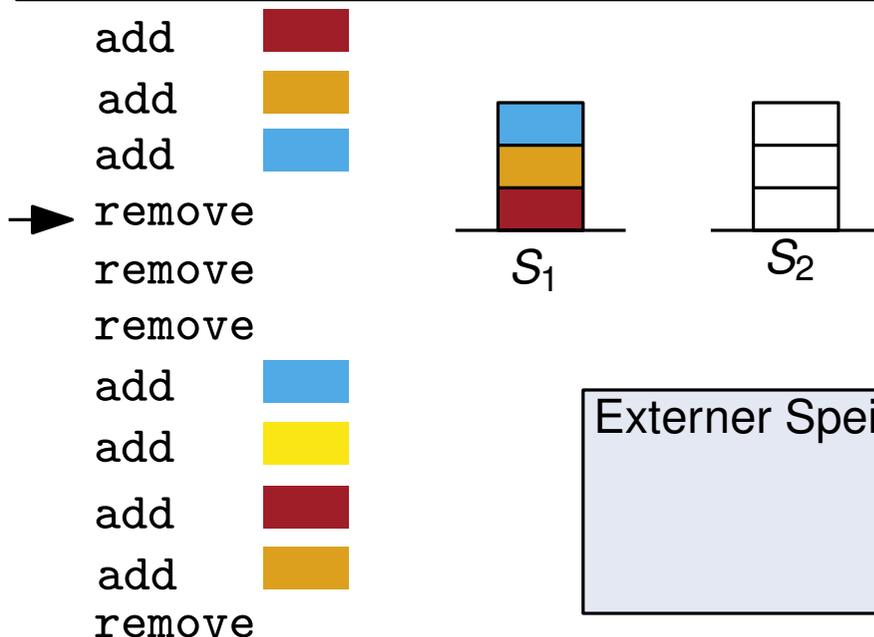
Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add(e)`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`S1.clear()`

`S1.push(e)`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer War-  
teschlange.

**wenn  $S_2$  leer dann**

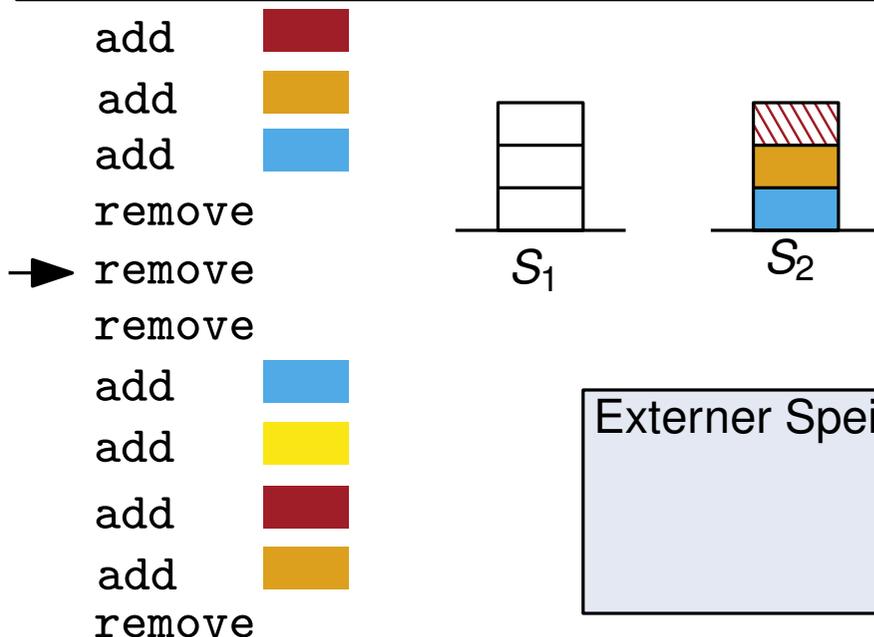
Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`S1.clear()`

`S2.pop()`



Externer Speicher:

# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add(e)`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`S1.clear()`

`S1.push(e)`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer War-  
teschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`S1.clear()`

`S2.pop()`

add 

add 

add 

remove

remove

➔ remove

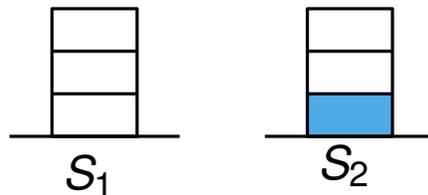
add 

add 

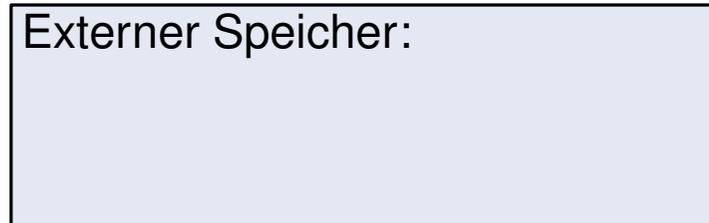
add 

add 

remove



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer War-  
teschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

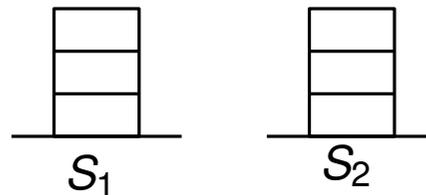
**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

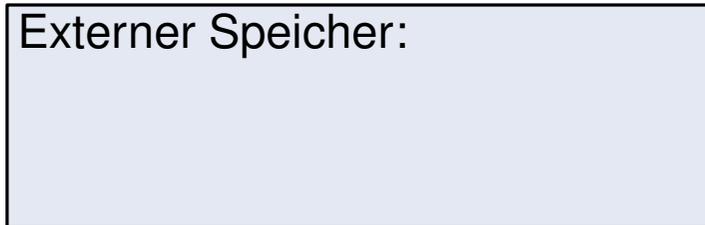
`$S_2$ .pop()`

add   
add   
add   
remove  
remove  
remove



➔ add   
add   
add   
add   
remove

Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add(e)`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`S1.clear()`

`S1.push(e)`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer War-  
teschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`S1.clear()`

`S2.pop()`

add 

add 

add 

remove

remove

remove

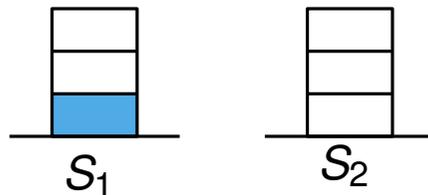
add 

➔ add 

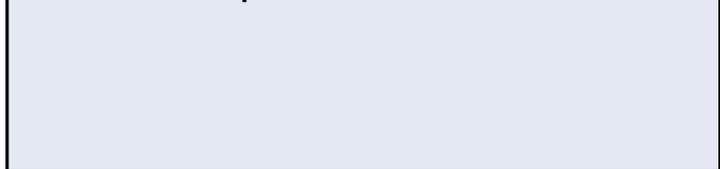
add 

add 

remove



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer War-  
teschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

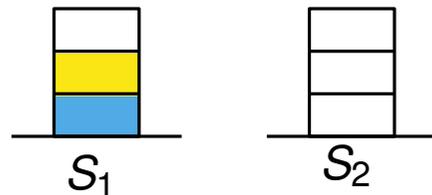
**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

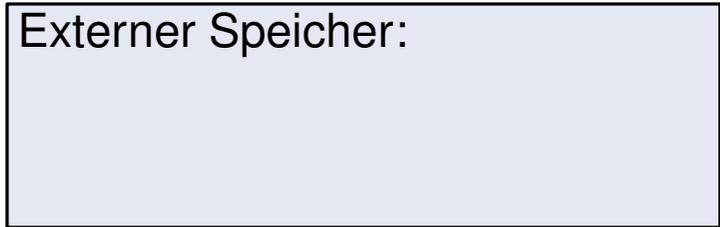
`$S_1$ .clear()`

`$S_2$ .pop()`

add   
 add   
 add   
 remove  
 remove  
 remove  
 add   
 add   
 → add   
 add   
 remove



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`

add 

add 

add 

remove

remove

remove

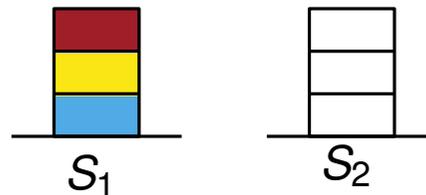
add 

add 

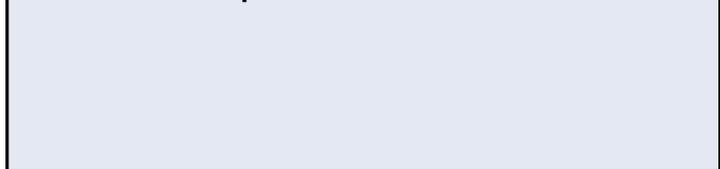
add 

→ add 

remove



Externer Speicher:



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:  
Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

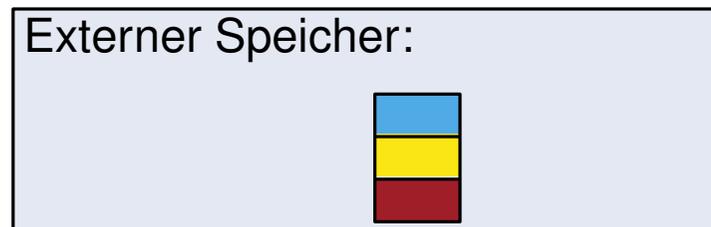
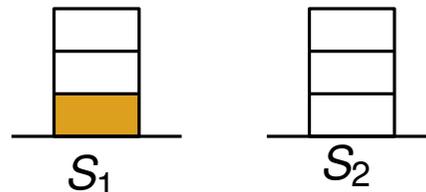
**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`

add   
add   
add   
remove  
remove  
remove  
add   
add   
add   
add   
remove



# Externe Warteschlange

Kann mithilfe von zwei internen Stacks  $S_1$  und  $S_2$  der Größe  $B$  umgesetzt werden.

**Idee:**  $S_1$  ist Schreib-Puffer und  $S_2$  ist Lese-Puffer.

Operation `add( $e$ )`:

Effekt: Hängt  $e$  an externe Warteschlange.

**wenn  $S_1$  voll dann**

Kopiere  $S_1$  in externen Speicher in  
verkehrter Reihenfolge.

`$S_1$ .clear()`

`$S_1$ .push( $e$ )`

Operation `remove()`:

Effekt: Entfernt erstes Element aus externer Warteschlange.

**wenn  $S_2$  leer dann**

Kopiere die  $B$  zuletzt geschriebenen  
Elemente aus dem externen Speicher  
in  $S_2$ .

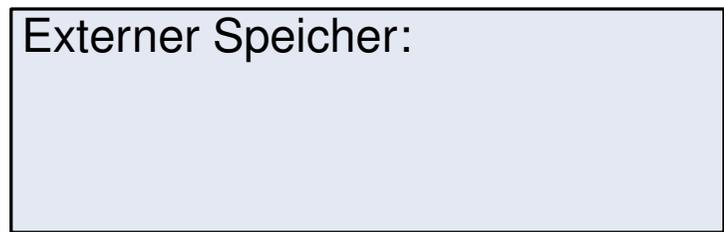
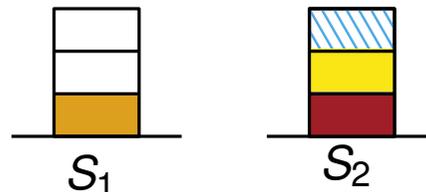
**wenn  $S_2$  immer noch leer dann**

Kopiere  $S_1$  in  $S_2$  in verkehrter  
Reihenfolge.

`$S_1$ .clear()`

`$S_2$ .pop()`

add   
add   
add   
remove  
remove  
remove  
add   
add   
add   
add   
remove



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

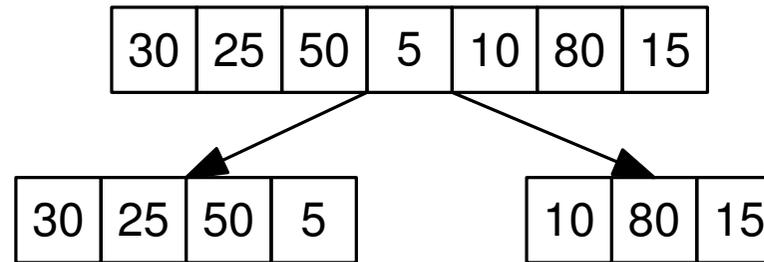
Laufzeit:  $O(n \log n)$

30	25	50	5	10	80	15
----	----	----	---	----	----	----

# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

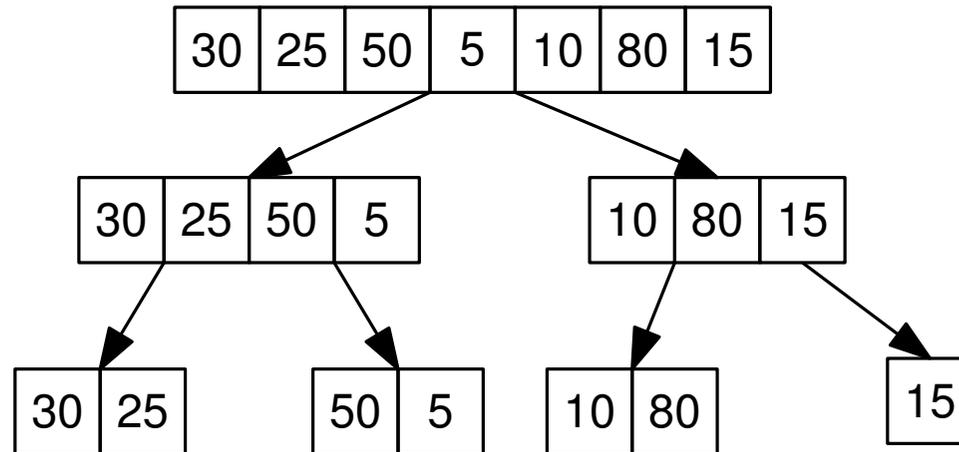
Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

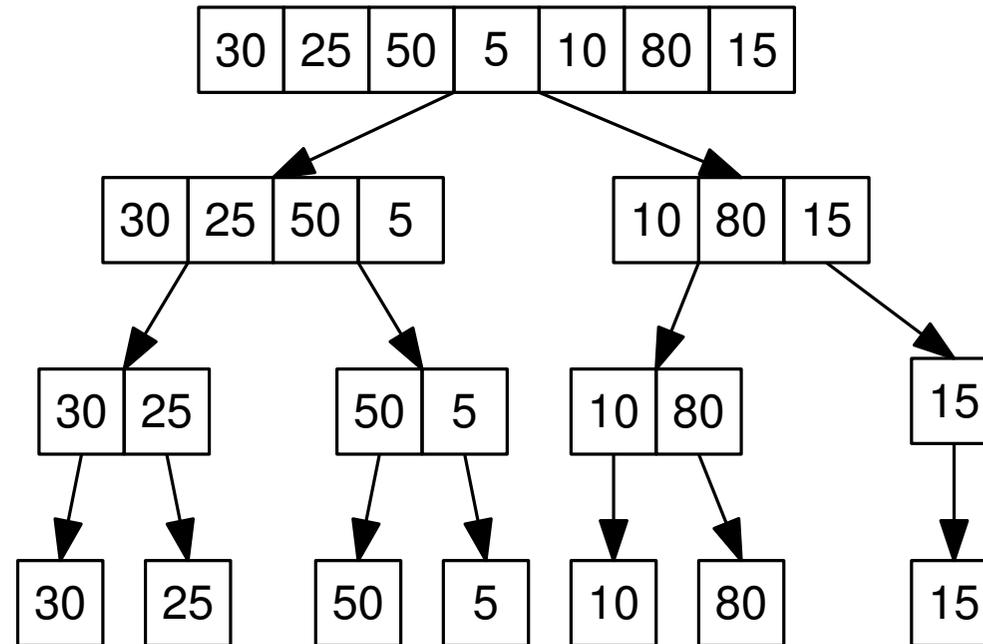
Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

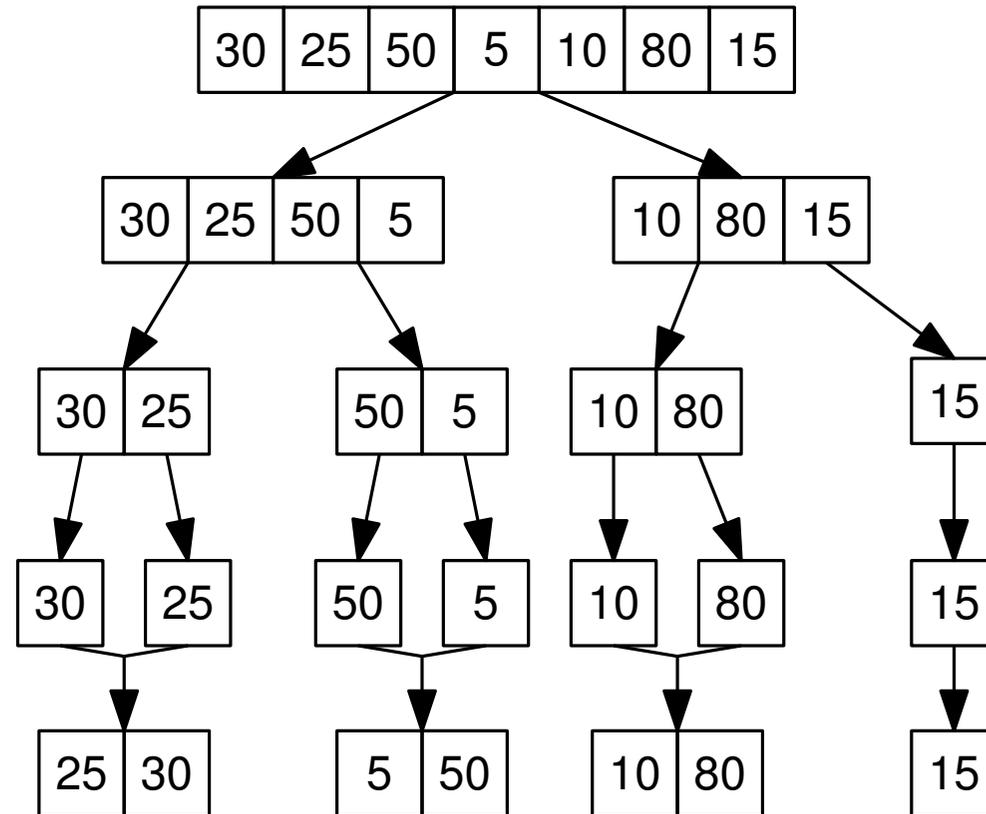
Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

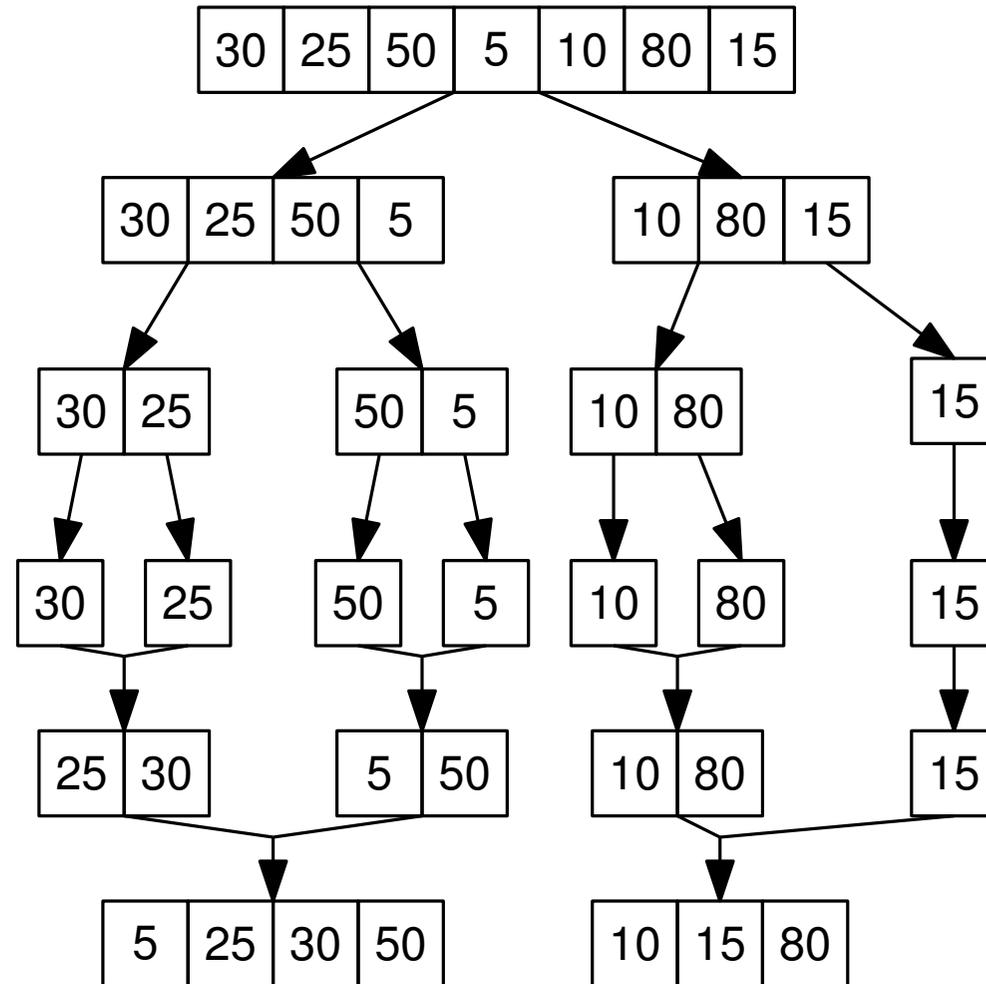
Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

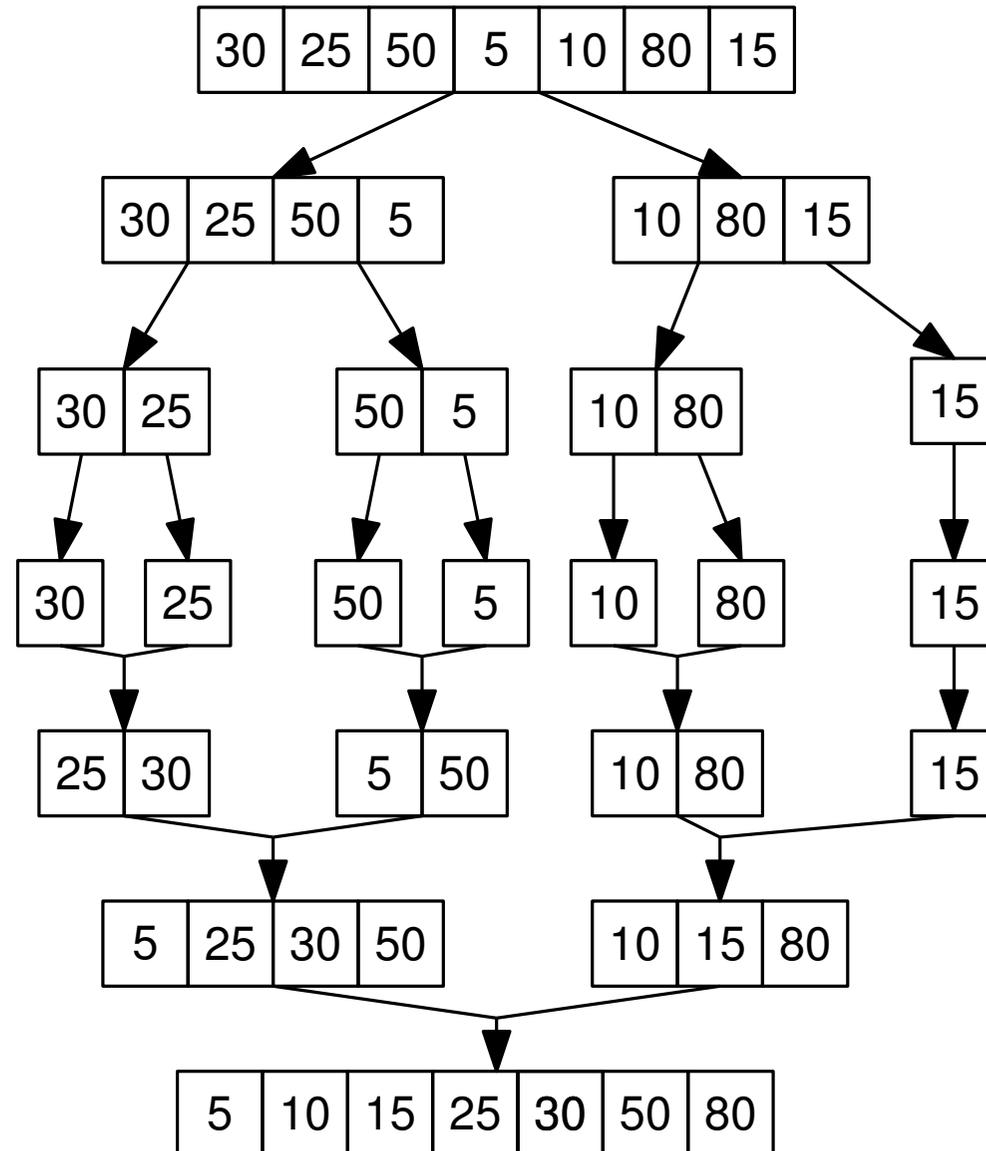
Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Erinnerung:** Prinzip von Merge Sort

Laufzeit:  $O(n \log n)$



# Multiway Merge Sort

**Eingabe:**  $a_1, \dots, a_n$  Elemente, die im externen Speicher liegen.

**Ausgabe:** Sortierung von  $a_1, \dots, a_n$ .

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

## 2. Phase: Merging

3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Vermenge hierzu möglichst viele Runs pro Durchgang.



Die folgenden Folien basieren auf dem Paper:

*Asynchronous parallel disk sorting*, R. Dementiev and P. Sanders. In 15th ACM Symposium on Parallelism in Algorithms and Architectures, pages 138–148, San Diego, 2003.

Entsprechend sind die Nummerierungen gewählt.

# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Beispiel  $m = 4$  und  $B = 2$ :

Hauptspeicher

Externer Speicher

$G_1 =$ 

m	a	k	e	*	t	h	i	n	g	s	*
---	---	---	---	---	---	---	---	---	---	---	---

a	s	*	s	i	m	p	l	e	*	a	s
---	---	---	---	---	---	---	---	---	---	---	---

 $= G_2$

$G_3 =$ 

*	p	o	s	s	i	b	l	e	*	b	u
---	---	---	---	---	---	---	---	---	---	---	---

t	*	n	o	*	s	i	m	p	l	e	r
---	---	---	---	---	---	---	---	---	---	---	---

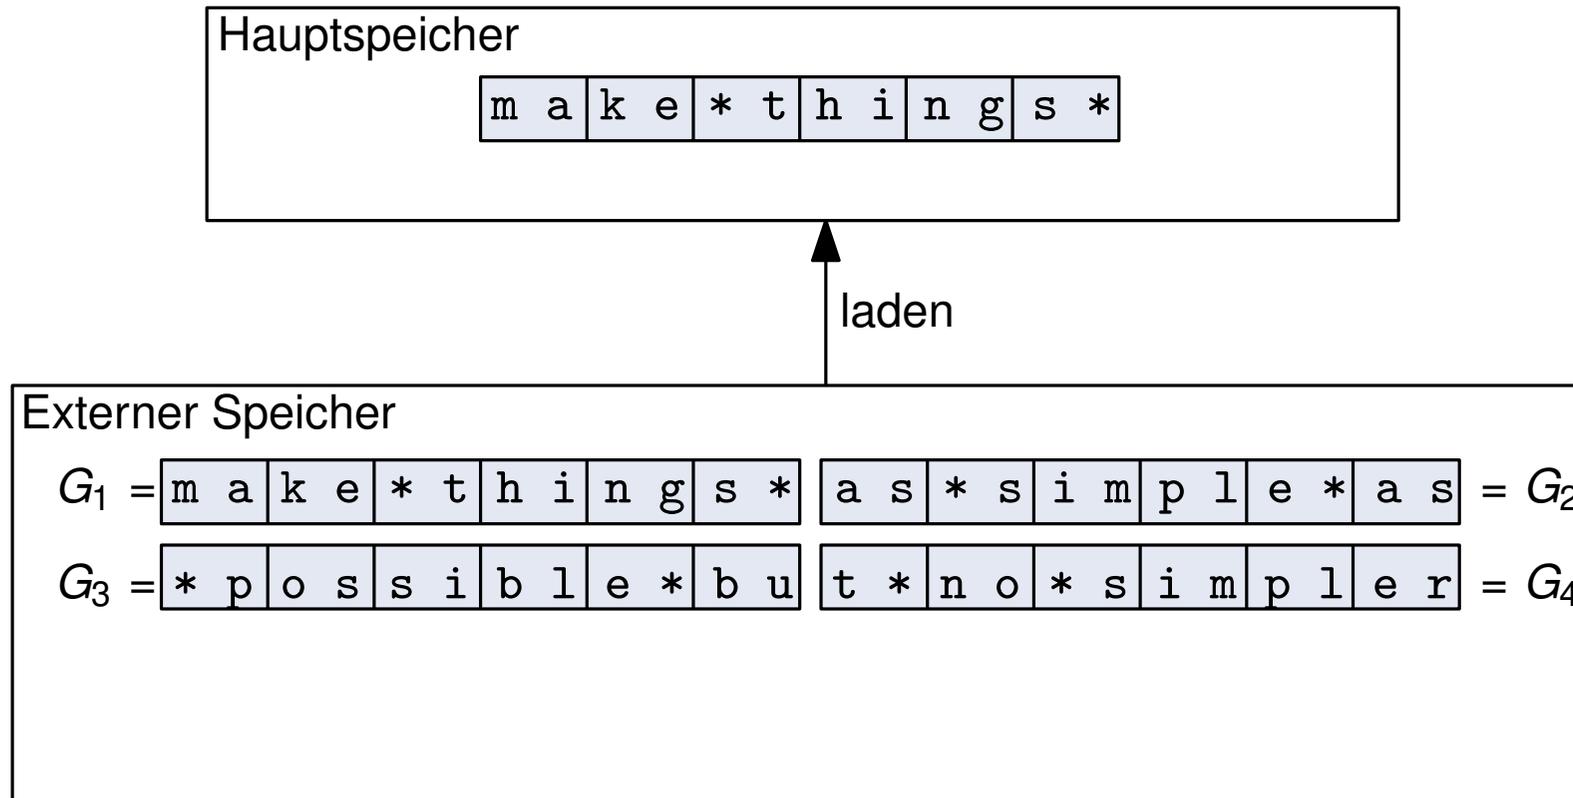
 $= G_4$

# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Beispiel  $m = 4$  und  $B = 2$ :

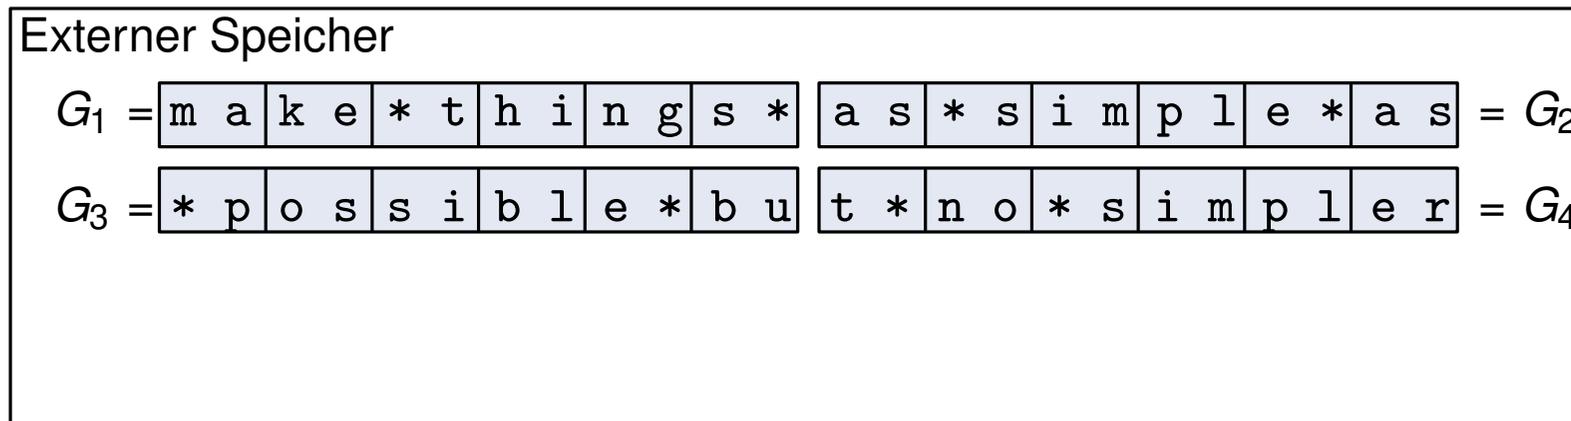
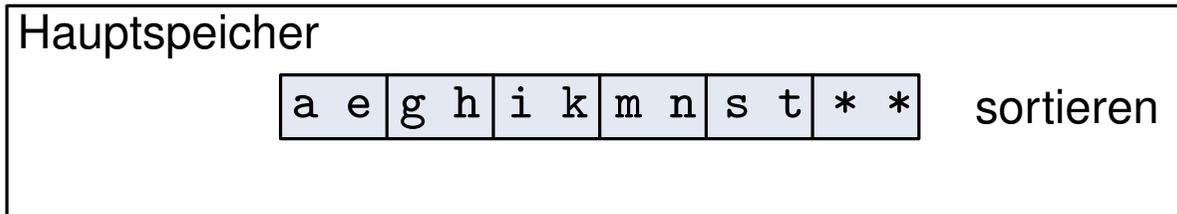


# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Beispiel  $m = 4$  und  $B = 2$ :

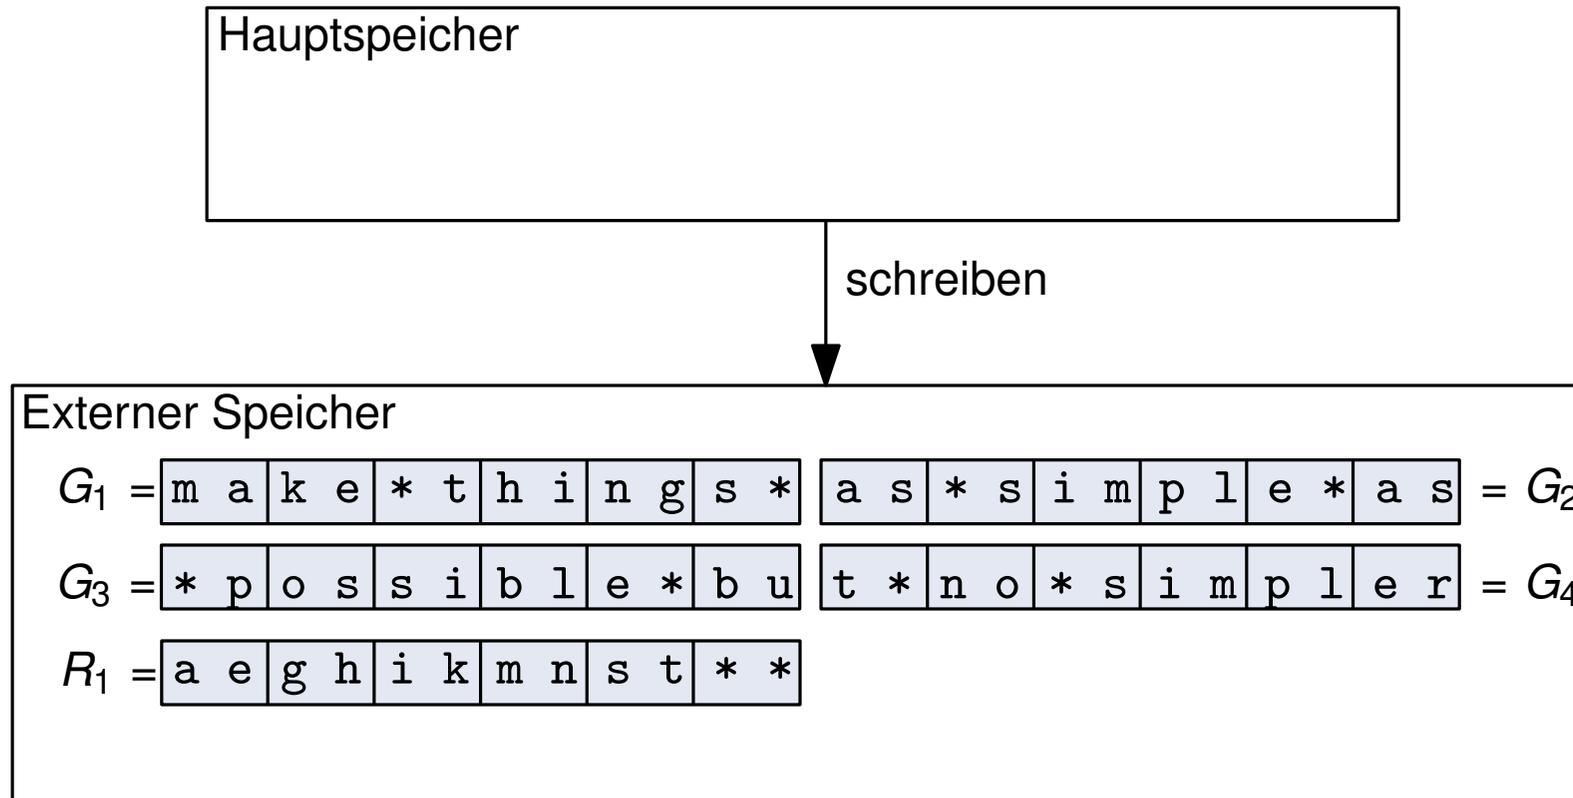


# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Beispiel  $m = 4$  und  $B = 2$ :

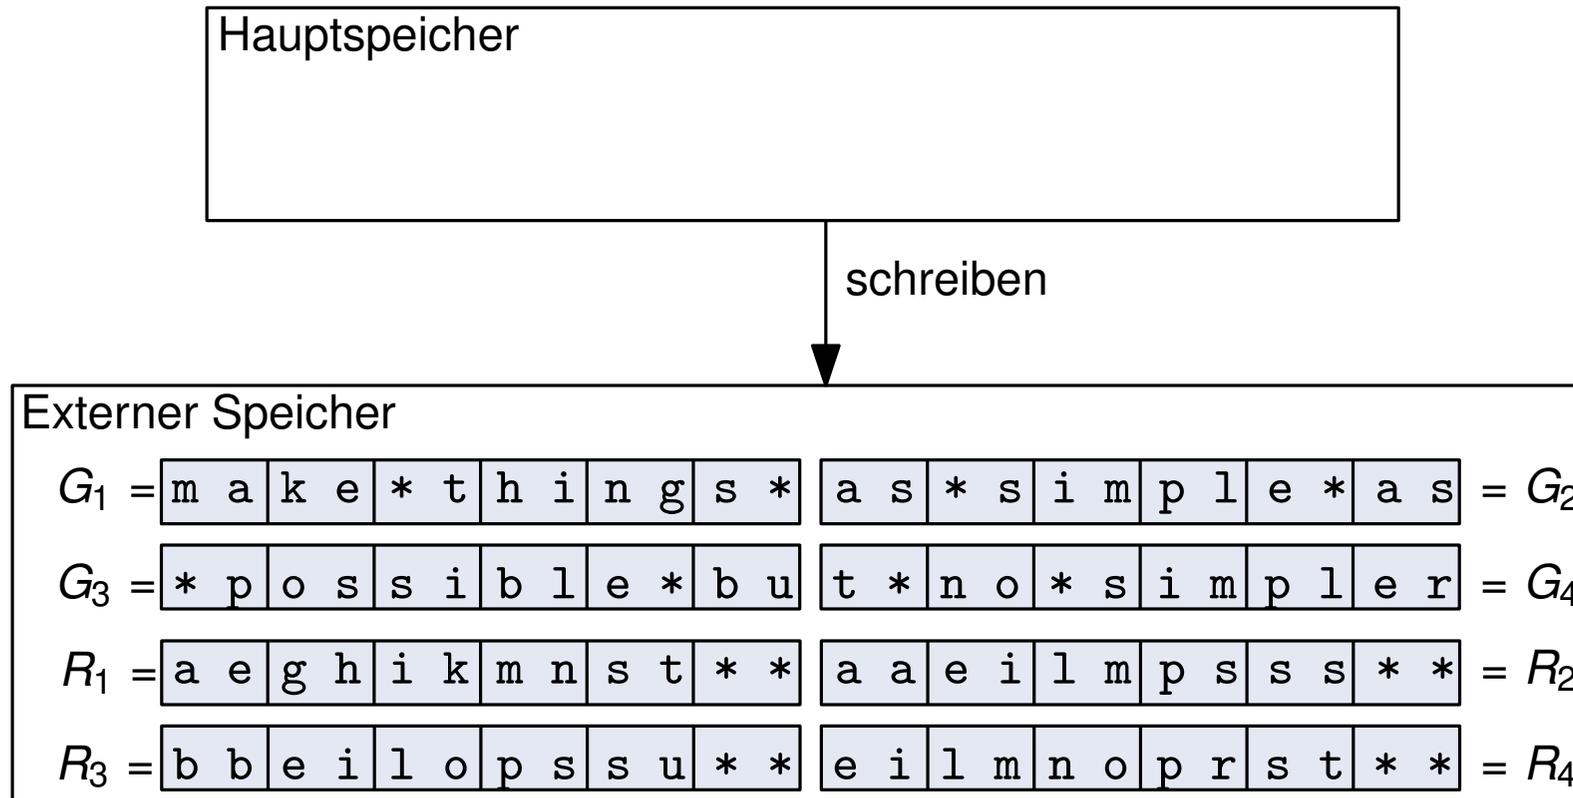


# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Beispiel  $m = 4$  und  $B = 2$ :



# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
  2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.
- *I/O-beschränkt*: I/O-Operationen benötigen mehr Zeit, als das Sortieren.
  - *berechnungsbeschränkt*: Sortieren benötigt mehr Zeit als I/O-Operationen.



**Beobachtung:**  $G_2$  könnte bereits in den Speicher geladen werden, solange  $G_1$  bearbeitet wird.

Verwende *Overlapping*-Technik: Teile Arbeit auf zwei Threads auf:

- Thread *A*: Verantwortlich für das Laden und Schreiben der Daten.
- Thread *B*: Verantwortlich für die eigentliche Arbeit auf den geladenen Daten.

# 1. Phase: Run Formation

## 1. Phase: Run Formation

1. Teile  $a_1, \dots, a_n$  in  $m$  Gruppen  $G_1, \dots, G_m$  der Größe  $\Theta(M)$  auf.
2. Lade jede Gruppe  $G_i$  in den Hauptspeicher, sortiere sie und schreibe sie zurück in den externen Speicher: Man erhält  $\mathcal{R} = \{R_1, \dots, R_m\}$  sortierte *Runs*.

Lade  $G_1$  und  $G_2$  in den Hauptspeicher.

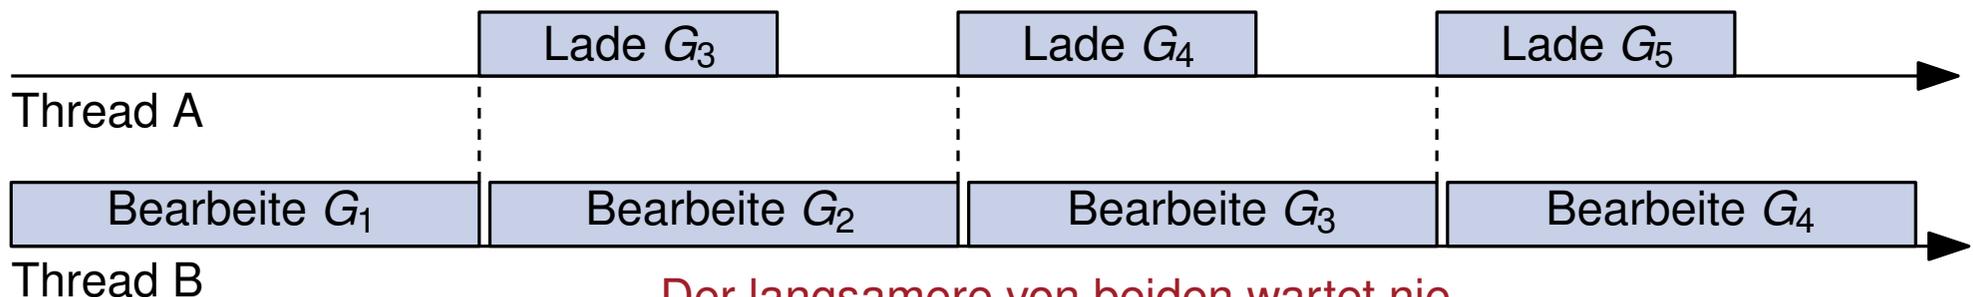
Thread A:

**für**  $i = 1, \dots, m - 2$  **tue**  
    **Warte** bis  $G_i$  in den externen Speicher  
    geschrieben wurde.  
    Lade  $G_{i+2}$  in den Hauptspeicher.

Thread B:

**für**  $i = 1, \dots, m$  **tue**  
    **Warte** bis  $G_i$  in den Hauptspeicher  
    geladen wurde.  
    Sortiere Gruppe  $G_i$ .  
    Schreibe  $G_i$  in externen Speicher.

Annahme: berechnungsbeschränkt



Der langsamere von beiden wartet nie.

# 1. Phase: Run Formation

**Korollar 2:** Eine Eingabe der Größe  $N$  kann in Zeit

$$\max\left\{2T_{\text{sort}}\left(\frac{M}{2}\right)\frac{N}{M}, \frac{2LN}{DB}\right\} + O\left(\frac{LM}{DB}\right)$$

in sortierte Runs der Größe  $\frac{M}{2} - O(DB)$  transformiert werden. Dabei bezeichnet  $T_{\text{sort}}(n)$  die Zeit, die benötigt wird um  $n$  Elemente intern zu sortieren und  $L$  die Zeit, die für einen I/O-Schritt benötigt wird.

## Notation:

- $M$ : Größe des Hauptspeichers.
- $N$ : Größe der Instanz:
- $D$ : Anzahl der Platten des externen Speichers.
- $B$ : Anzahl Elemente in einem Block.
- $L$ : Zeit, die für einen I/O-Schritt benötigt wird (Latenz).



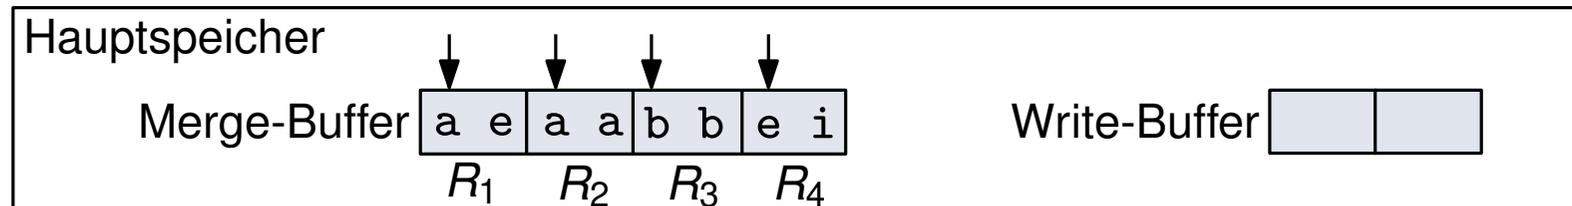
# 2. Phase: Merging

## 2. Phase: Merging

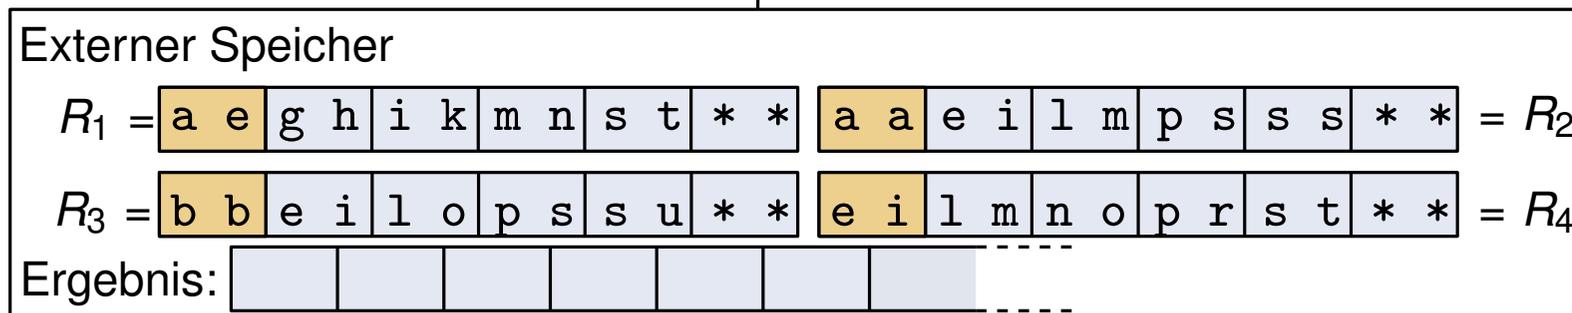
3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



Lade Blöcke.



$B = 2$   
 $D = 1$

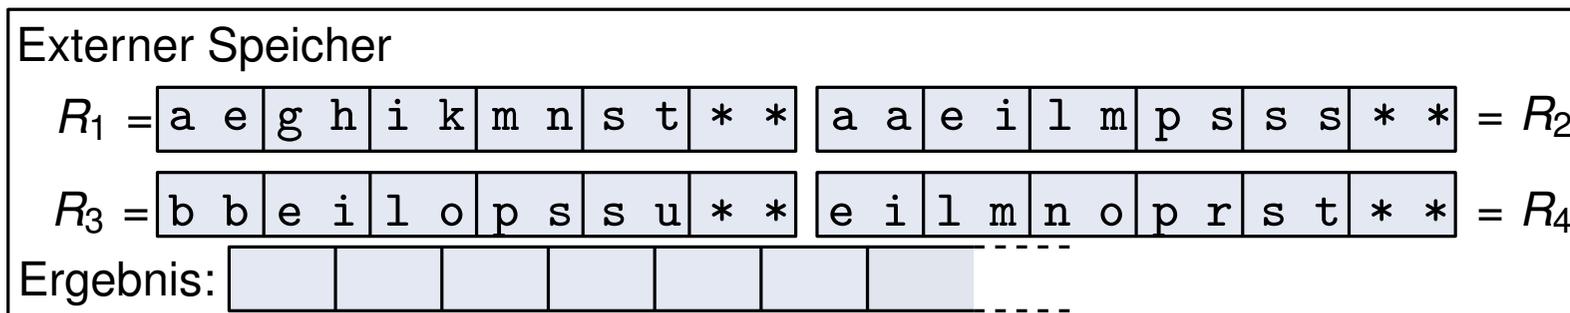
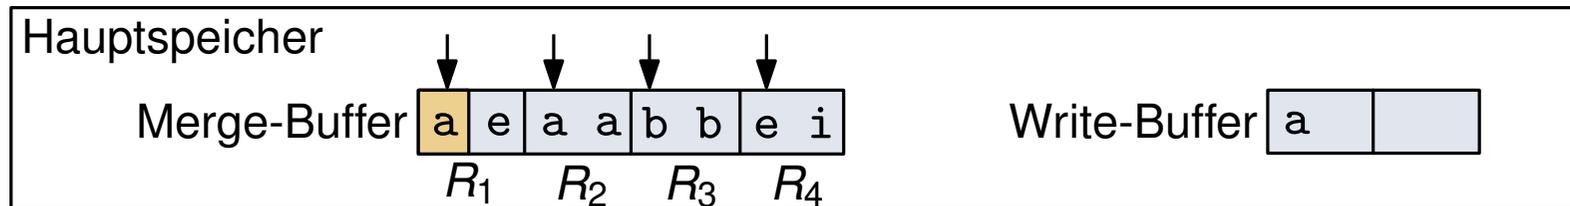
# 2. Phase: Merging

## 2. Phase: Merging

3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



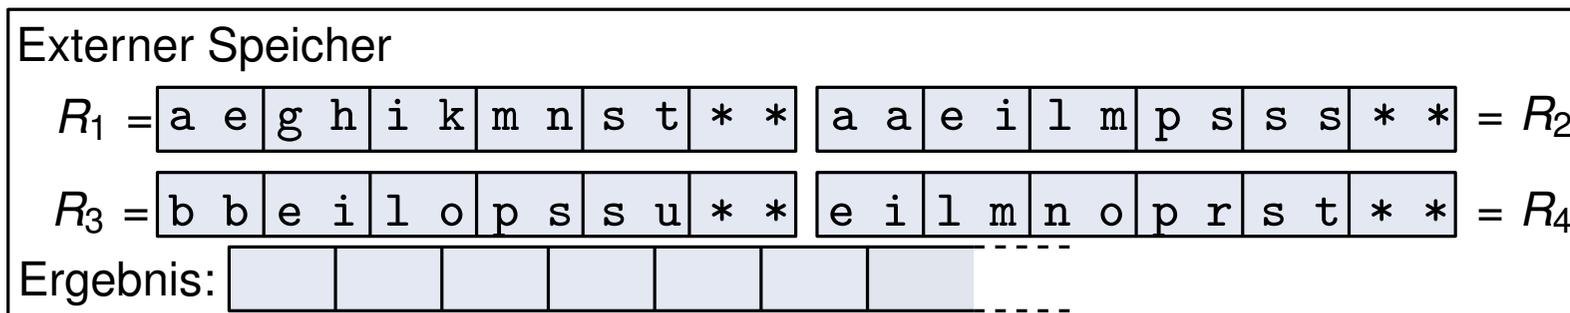
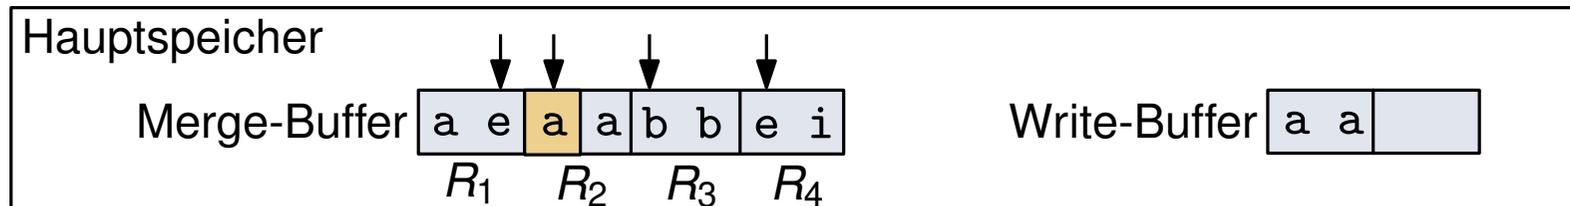
# 2. Phase: Merging

## 2. Phase: Merging

3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



$B = 2$   
 $D = 1$

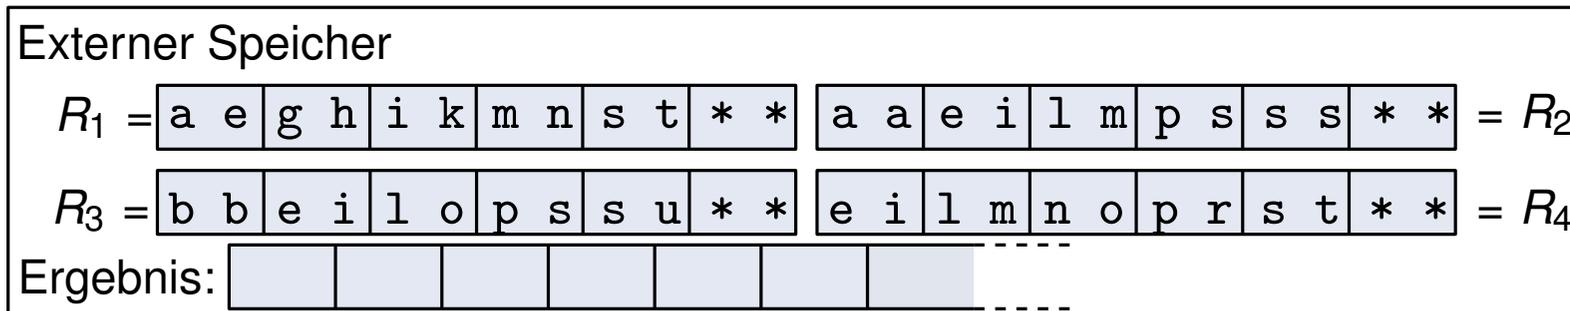
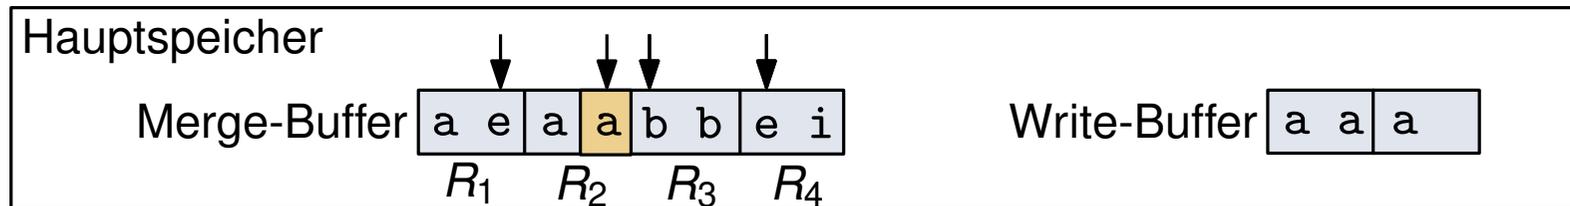
# 2. Phase: Merging

## 2. Phase: Merging

3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



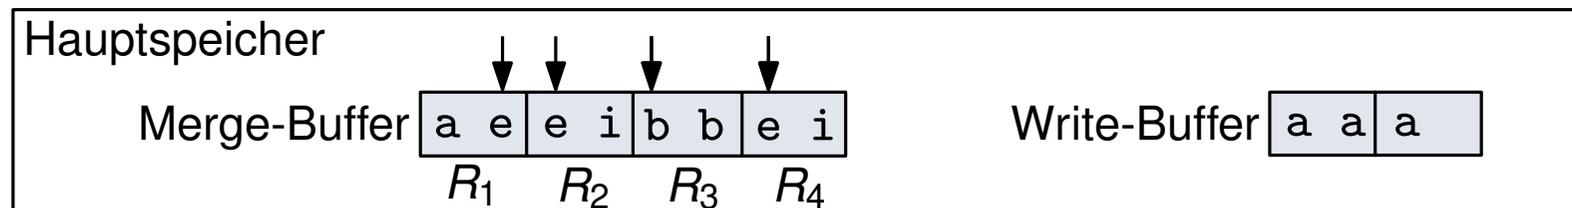
# 2. Phase: Merging

## 2. Phase: Merging

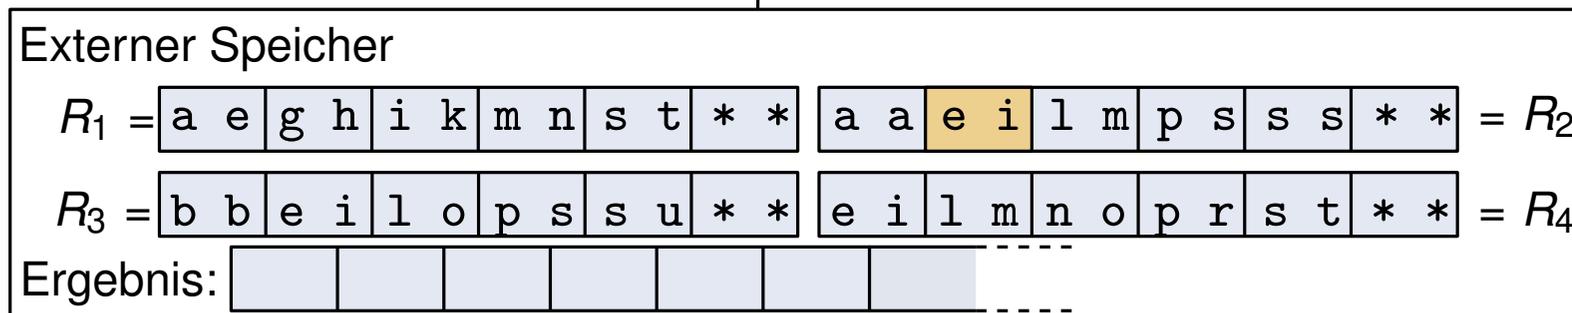
3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



Lade Block aus  $R_2$ .



$B = 2$   
 $D = 1$

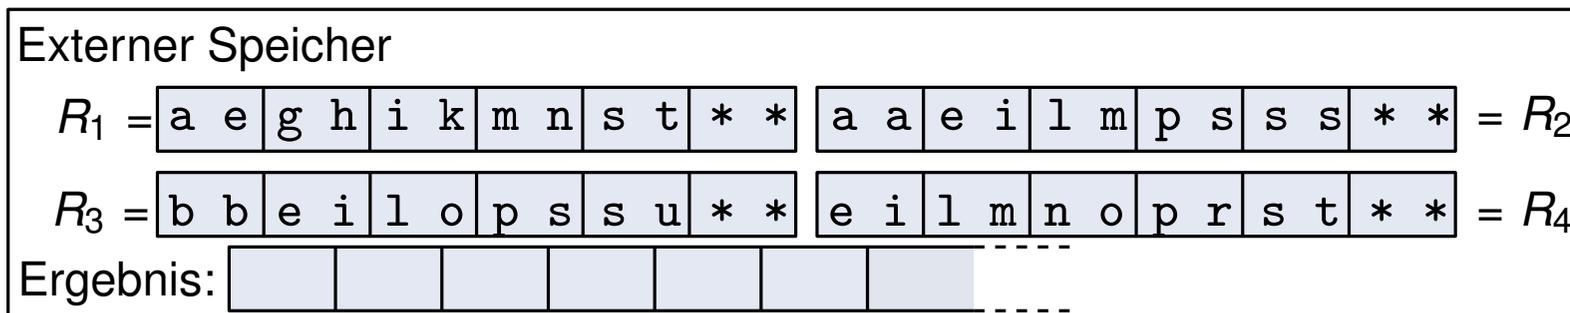
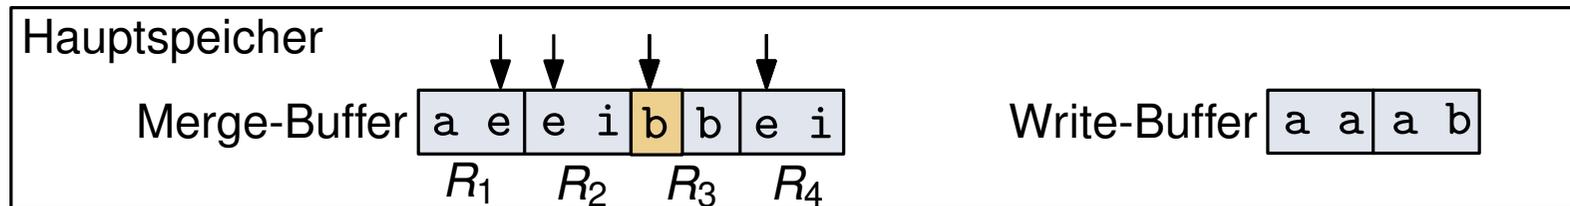
# 2. Phase: Merging

## 2. Phase: Merging

3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



$B = 2$   
 $D = 1$

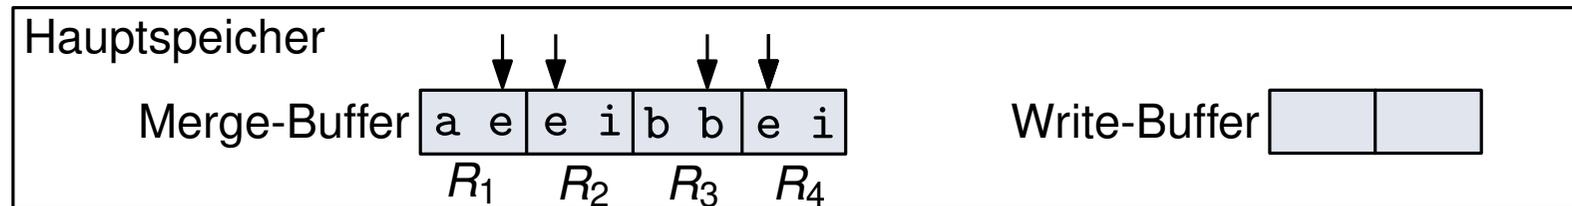
# 2. Phase: Merging

## 2. Phase: Merging

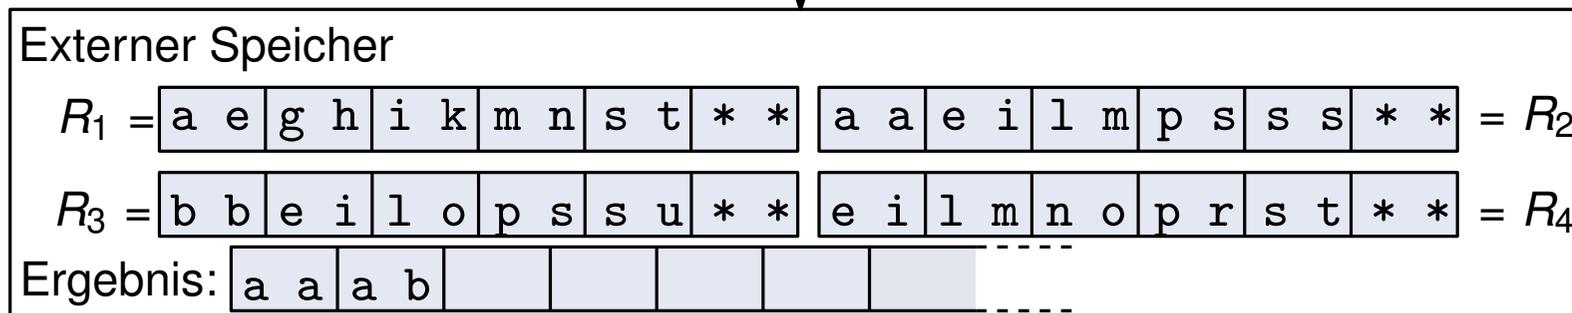
3. Vereinige die einzelnen Runs ordnungserhaltend zu größeren, bis schließlich einer übrig bleibt. Es können  $k = O(\frac{M}{B})$  Runs in einem Durchgang vereinigt werden.

Vereinige  $k$  Runs in einem Durchlauf (MULTIWAY MERGING):

1. Halte nur den Block pro Run im Hauptspeicher (*Merge-Buffer*), der das aktuell kleinste Element enthält.
2. Vereinige Blöcke im Merge-Buffer schrittweise und schreibe Ergebnis in den Write-Buffer.
3. Lade bei Bedarf Blöcke nach und schreibe Write-Buffer in externen Speicher.



Kopiere Write-Buffer in externen Speicher.



$B = 2$   
 $D = 1$

## 2. Phase: Merging

**Lemma 3:** Zu jedem Zeitpunkt von MULTIWAY MERGING ist das kleinste Element im Merge-Buffer unter allen Elementen, die noch nicht von der Merge-Prozedur betrachtet worden sind, minimal.

# Tournament-Bäume

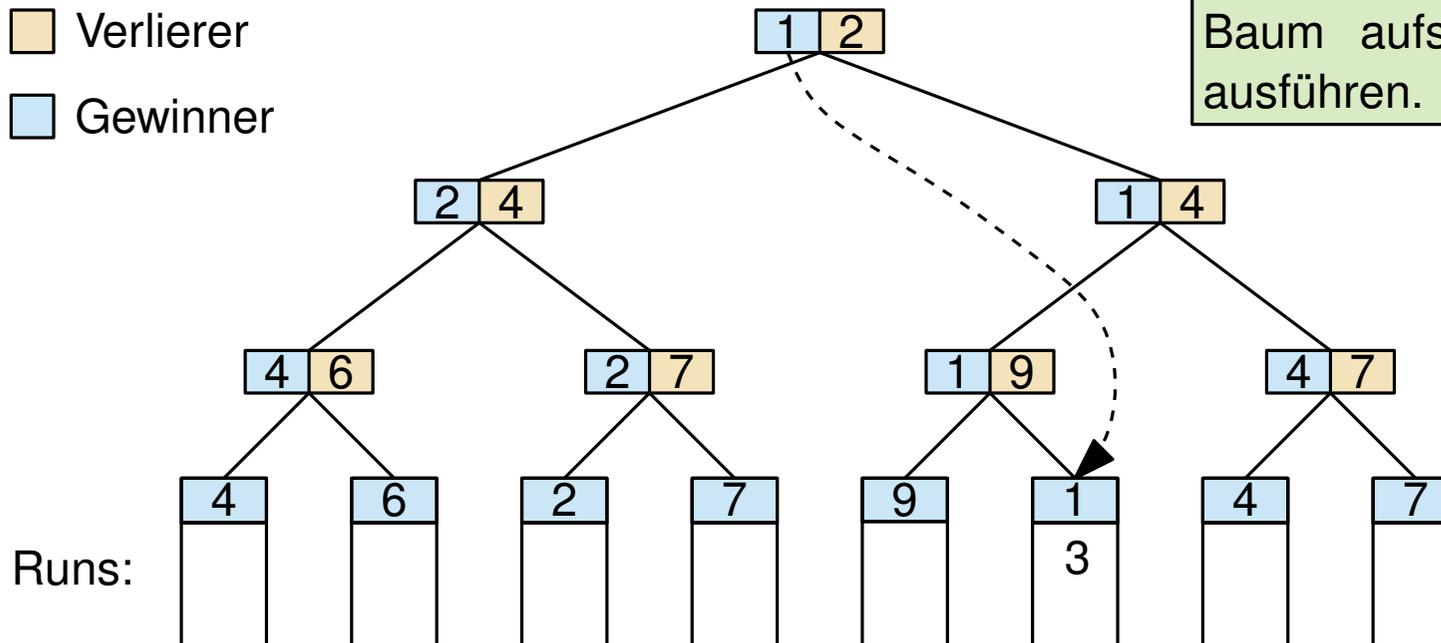
Wie kann das kleinste Element im Merge-Buffer schnell gefunden werden?

Ein *Tournament-Baum* ist ein binärer Baum mit  $k$  Blättern, sodass

- das  $i$ -te Blatt das kleinste Element vom  $i$ -ten Run enthält, und
- jeder innere Knoten den Gewinner und den Verlierer des Wettkampfes zwischen den Gewinnern seiner zwei Kindern enthält. Es gilt: Gewinner  $<$  Verlierer und Blätter enthalten nur Gewinner.

Minimum entfernen und Baum aktualisieren ist in  $O(\log n)$  Zeit möglich.  
**Grundidee:** Lasse neuen Wert im Baum aufsteigen und Wettkämpfe ausführen.

■ Verlierer  
■ Gewinner



# Tournament-Bäume

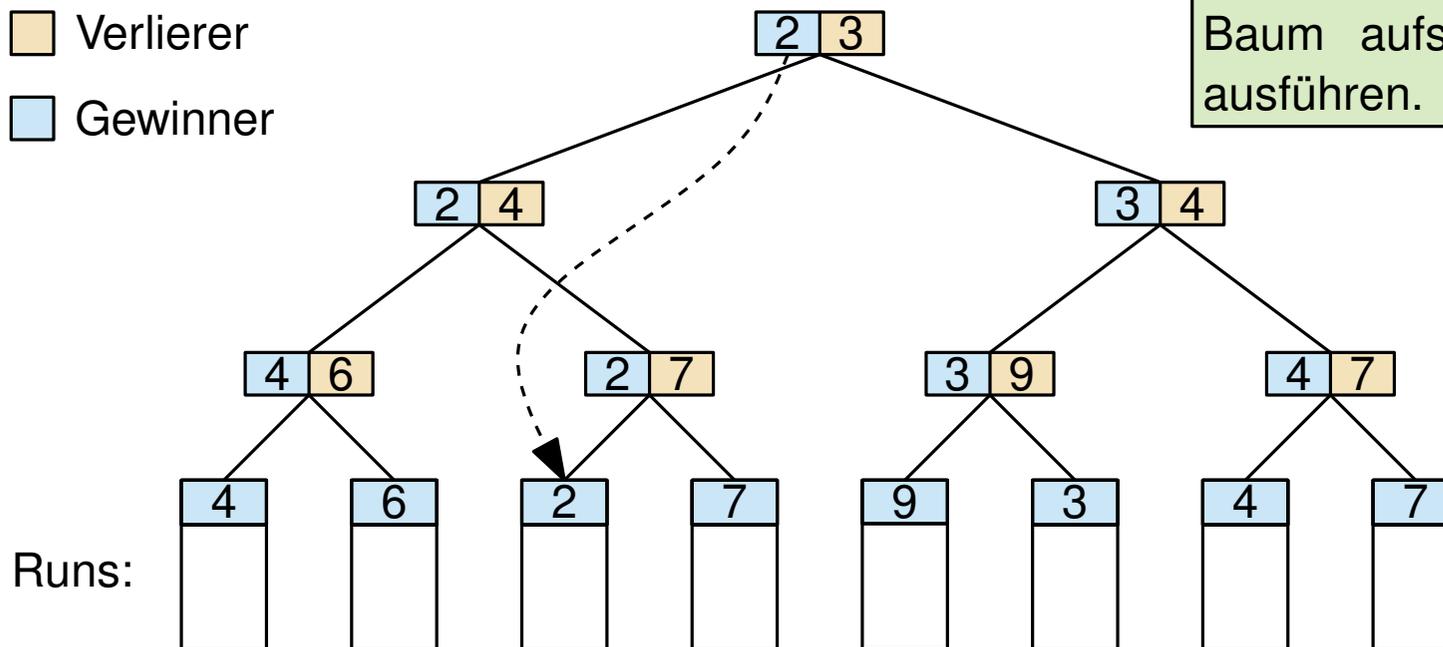
Wie kann das kleinste Element im Merge-Buffer schnell gefunden werden?

Ein *Tournament-Baum* ist ein binärer Baum mit  $k$  Blättern, sodass

- das  $i$ -te Blatt das kleinste Element vom  $i$ -ten Run enthält, und
- jeder innere Knoten den Gewinner und den Verlierer des Wettkampfes zwischen den Gewinnern seiner zwei Kindern enthält. Es gilt: Gewinner  $<$  Verlierer und Blätter enthalten nur Gewinner.

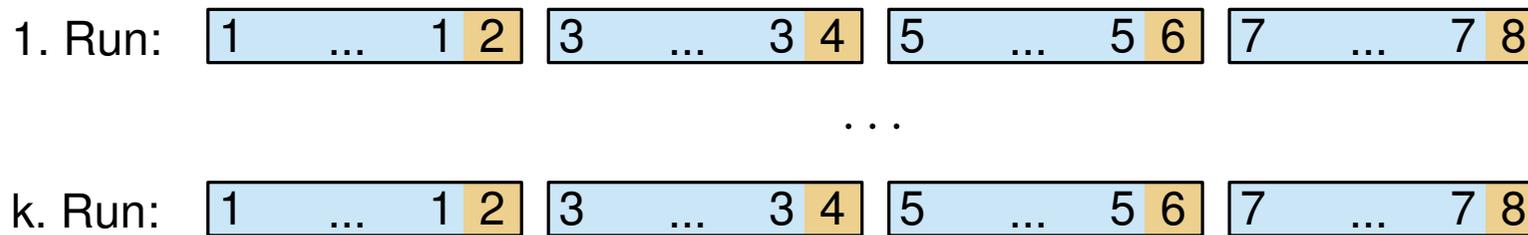
Minimum entfernen und Baum aktualisieren ist in  $O(\log n)$  Zeit möglich.  
**Grundidee:** Lasse neuen Wert im Baum aufsteigen und Wettkämpfe ausführen.

■ Verlierer  
■ Gewinner



## 2. Phase: Merging

Schwierig den internen Aufwand abzuschätzen, der beim Vereinigen entsteht, da Lesen und Schreiben nicht vom Vereinigen getrennt sind. Betrachte hierzu folgende  $k$  identische Runs:



### Ablauf:

- Nach Initialisierung der Merge-Buffers werden zuerst  $k \cdot (B - 1)$  Werte '1' verarbeitet.
- Nach Verarbeitung des Wertes '2' für alle  $k$  Runs werden die nächsten  $k$  Blöcke geladen.
- Diese werden wieder zuerst verarbeitet, bevor weitere Blöcke geladen werden, usw.

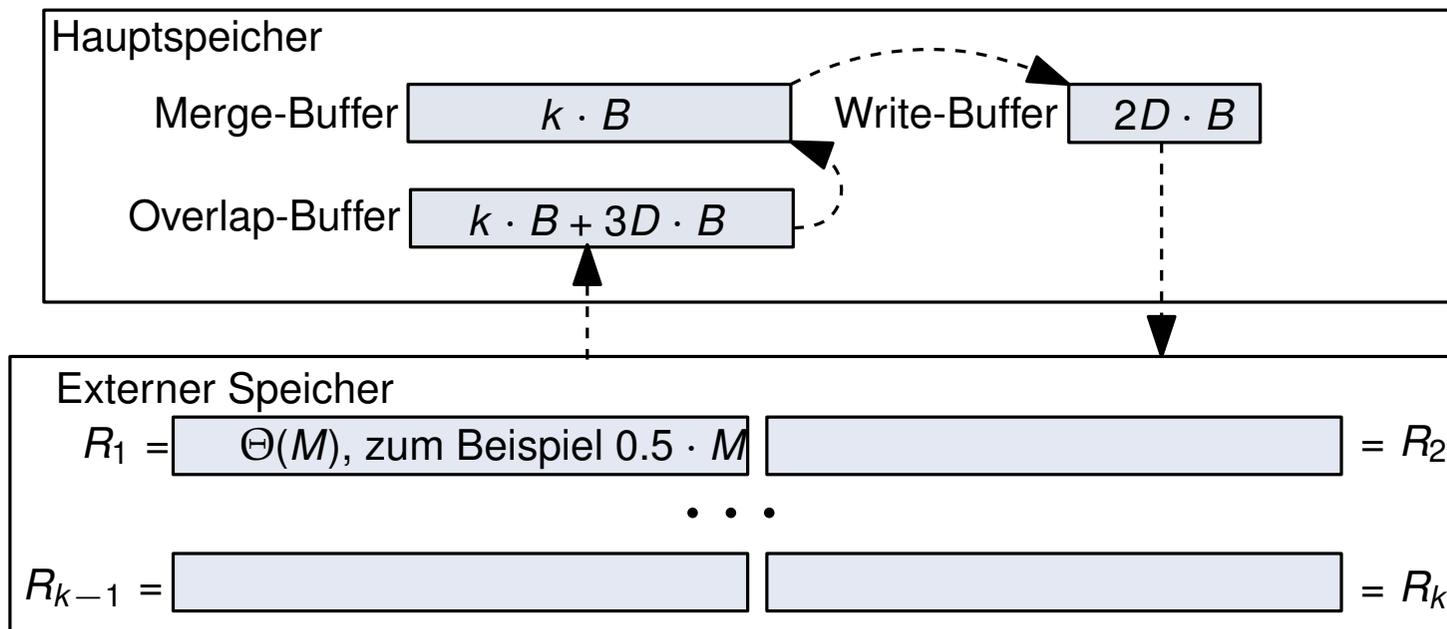
**Verbesserung:** Verwende wieder Overlapping-Technik, um I/O von Verarbeitung zu trennen:

- Thread  $A$ : Verantwortlich für I/O-Operationen.
- Thread  $B$ : Verantwortlich für das eigentliche Vermengen: Arbeitet ausschließlich auf dem Hauptspeicher.

## 2. Phase: Merging

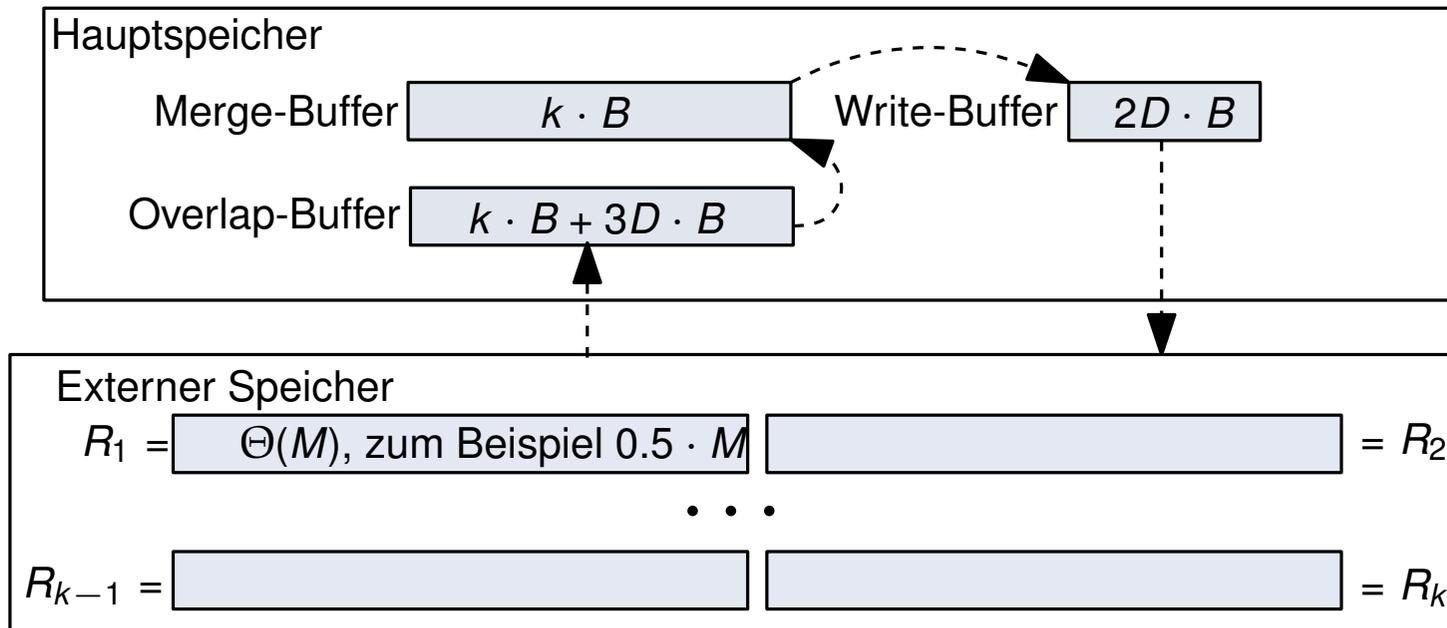
### Anpassungen:

- Führe *Overlap-Buffer* ein, um Blöcke gepuffert lesen zu können.
- I/O-Thread (Thread A):
  1. Falls gerade kein I/O aktiv und mindestens  $D \cdot B$  Elemente im Write-Buffer enthalten sind, dann schreibe Write-Buffer in den externen Speicher.
  2. Falls gerade kein I/O aktiv, weniger als  $D$  Blöcke im Write-Buffer sind und mindestens  $D$  Blöcke im Overlap-Buffer unbenutzt sind, dann lade die nächsten  $D$  Blöcke aus dem externen Speicher in den Overlap-Buffer.
- Merging-Thread (Thread B): Wie bisher, hole aber Daten aus dem Overlap-Buffer.



## 2. Phase: Merging

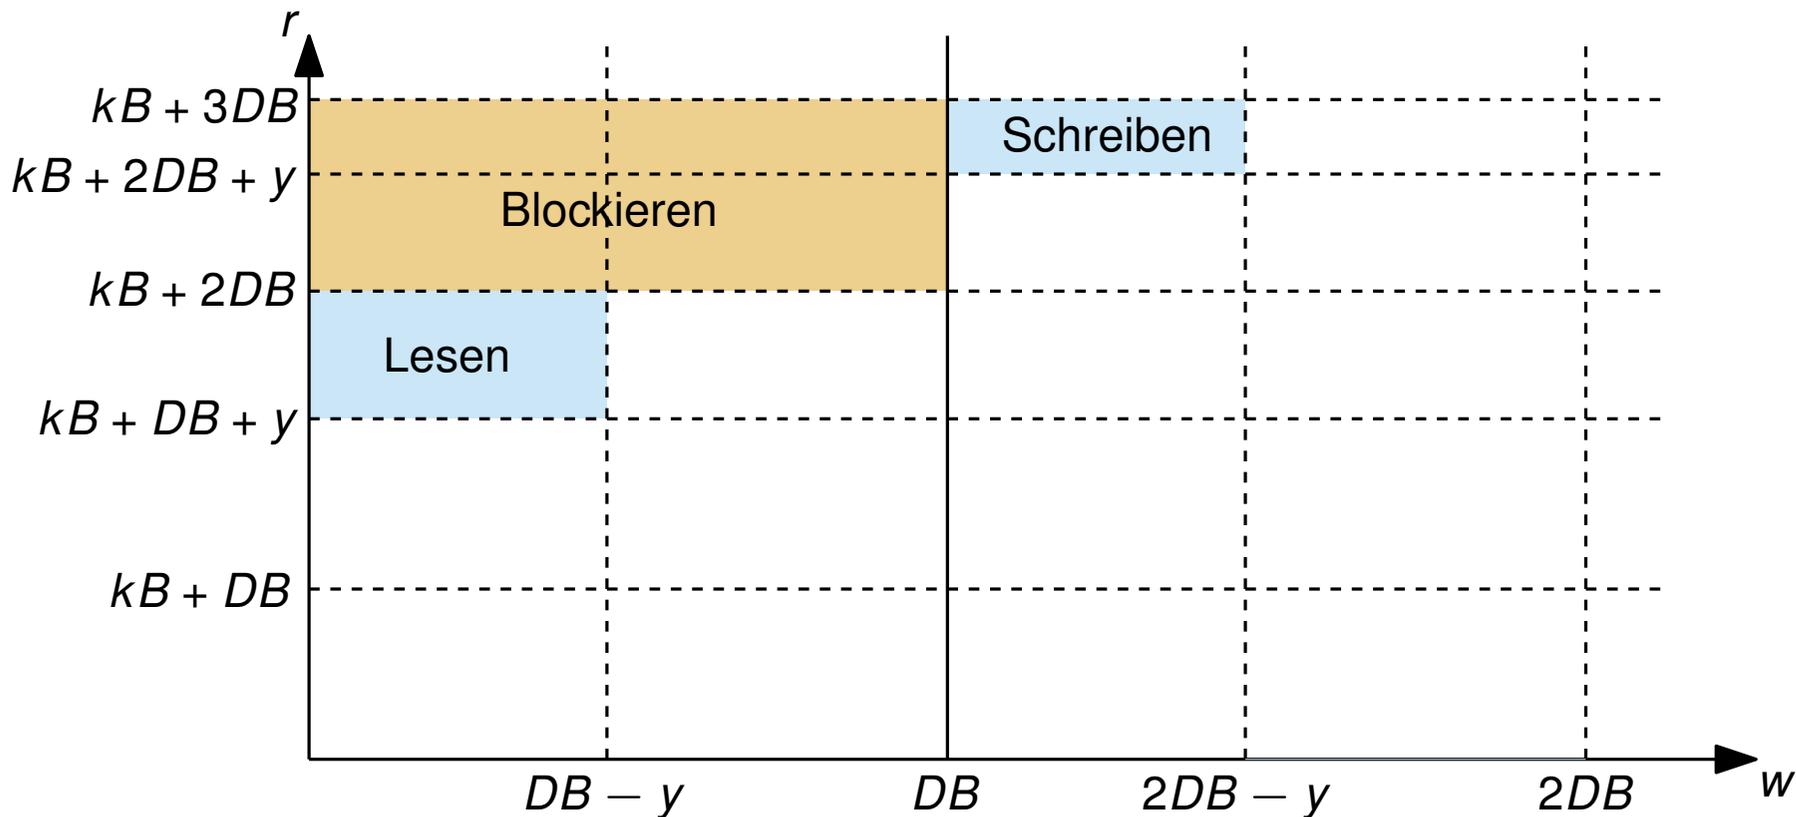
**Lemma 5:** Falls der Overlap-Buffer und der Merge-Buffer zusammen mindestens  $k \cdot B$  Elemente enthalten, dann kann mindestens ein weiteres Element vom Merging-Thread verarbeitet werden, ohne dass ein neuer Block aus dem externen Speicher geladen werden muss.



## 2. Phase: Merging

**Lemma 6:** Sei  $\ell$  die Zeit, die der Merging-Thread benötigt um ein Element der Ausgabe zu erzeugen und sei  $L$  die Zeit, die gebraucht wird um  $D$  beliebige Blöcke zu laden/speichern.

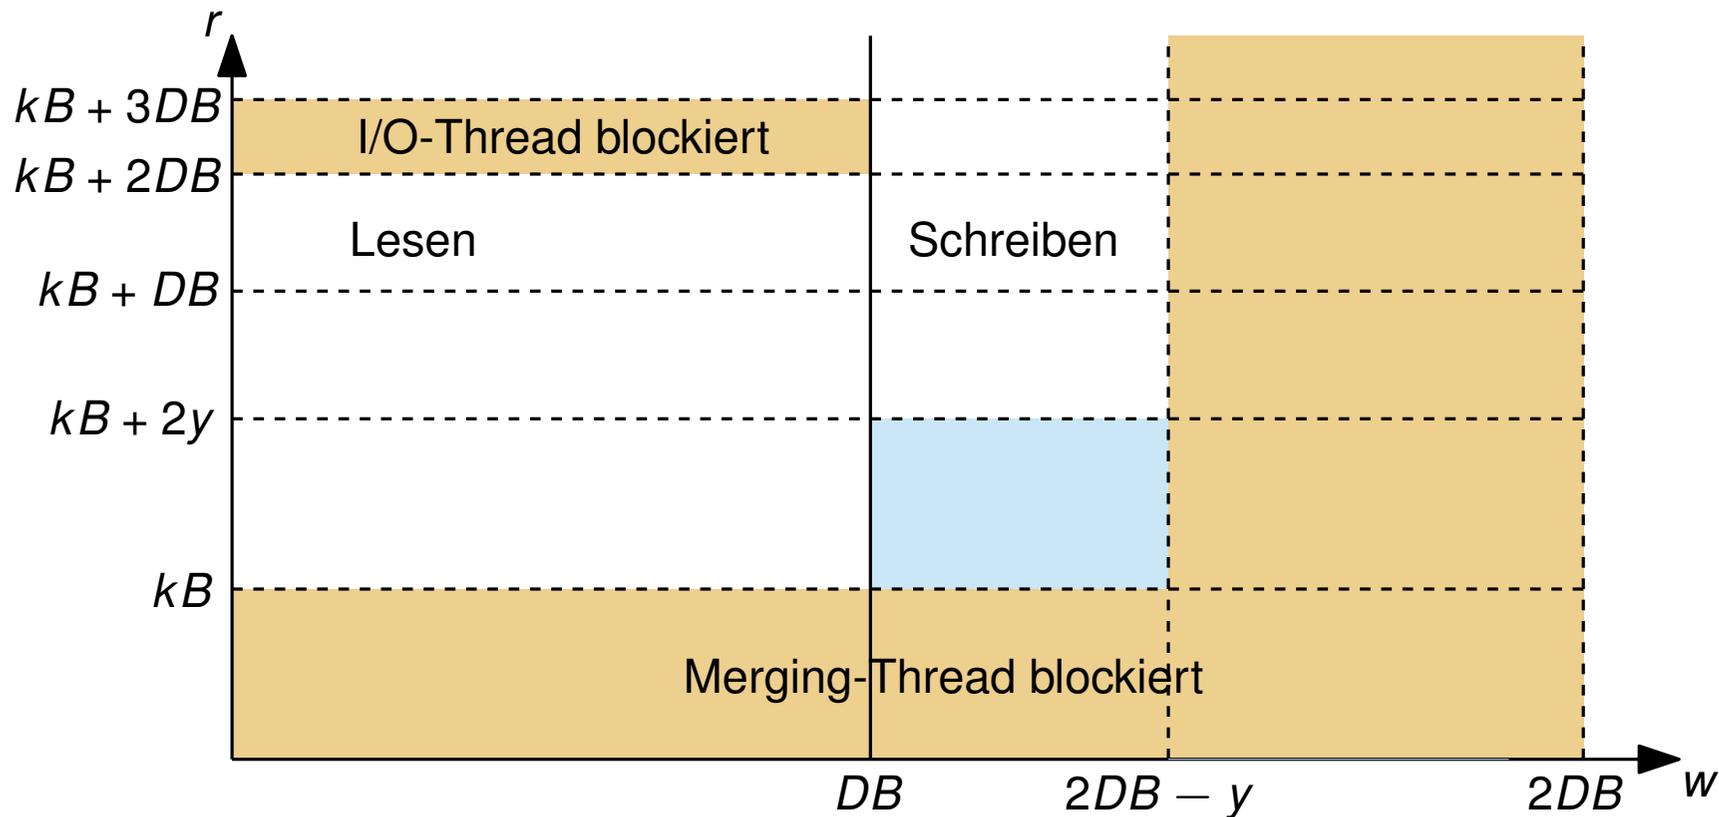
Falls  $2L \geq DB\ell$ , dann blockiert (wartet) der I/O-Thread erst dann, wenn alle Eingabeblocke gelesen worden sind.



## 2. Phase: Merging

**Lemma 7:** Sei  $\ell$  die Zeit, die der Merging-Thread benötigt um ein Element der Ausgabe zu erzeugen und sei  $L$  die Zeit, die gebraucht wird um  $D$  beliebige Blöcke zu laden/speichern.

Falls  $2L < DB\ell$ , dann wird der Merging-Thread nach  $\frac{k}{D} + 1$  I/O-Schritten erst dann wieder blockieren, wenn alle Elemente vermengt worden sind.



## 2. Phase: Merging

**Theorem 4:** Sei  $\ell$  die Zeit, die der Merging-Thread benötigt um ein Element der Ausgabe zu erzeugen und sei  $L$  die Zeit, die gebraucht wird um  $D$  beliebige Blöcke zu laden/speichern.

$k$  sortierte Runs, die zusammen  $n$  Elemente enthalten, können in Zeit

$$\max\left\{\frac{2Ln}{DB}, \ell n\right\} + O\left(L\left\lceil\frac{k}{D}\right\rceil\right)$$

vereinigt werden.