Sortierverfahren 2

- Sie kennen das Prinzip: "Teile und Herrsche"
- Sie kennen zwei schnelle Sortierverfahren: Quick Sort, Distribution Sort
- Sie können Algorithmen mittels Parallelisierung optimieren

Teile und Herrsche

Das Prinzip "Teile und Herrsche"

Teile und Herrsche - abgekürzt: TUH
Andere Bezeichnungen dieses Prinzips:
Divide et impera
Divide and conquer, Divide and rule

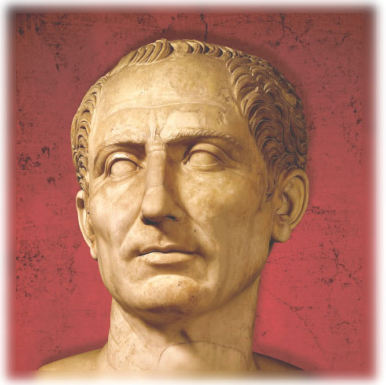

- Divide et impera wird - fälschlicherweise - Cäsar zugeschrieben
- Zerlege das Problem in kleinere, einfacher zu lösende Teile
  - Spezialfall: Teil = Ursprungsproblem mit kleinerem Bereich
- Löse die so erhaltenen Teilprobleme
- Füge die Teillösungen wieder zu einem Ganzen zusammen

Teile und Herrsche bei Sortieralgorithmen

School of Engineering

- Sortieralgorithmen nach dem Prinzip Teile und Herrsche.

```
if (Menge der Datenobjekte klein genug)
       Ordne sie direkt;
else {
       Teilen: Zerlege die Menge in Teilmengen;
       Ausführen: Sortiere jede der Teilmengen;
       Vereinigen: Füge die Teilmengen geordnet zusammen;
      }
```

- Solche Algorithmen sind typischerweise rekursiv:

```
Sort (Menge a)
       if (Menge der Datenobjekte klein genug)
              Ordne sie direkt;
       else {
              Zerlege in zwei Teilmengen
              Sort(Teilmenge1); Sort(Teilmenge2)
              Füge Teilmengen geordnet zusammen
       }
}
```

Bei der Zerlegung sollten die Teile möglichst gleich gross sein.

Idee des Quicksort

Quick-Sort

- Wurde **1960**
  von dem britischen
  Informatiker C.A.R. Hoare

Ich stelle fest, dass es zwei Wege gibt, ein Software-Design zu erstellen, entweder so einfach, dass es offensichtlich keine Schwächen hat, oder so kompliziert, dass es keine offensichtlichen Schwächen hat. Die erste Methode ist weitaus schwieriger.

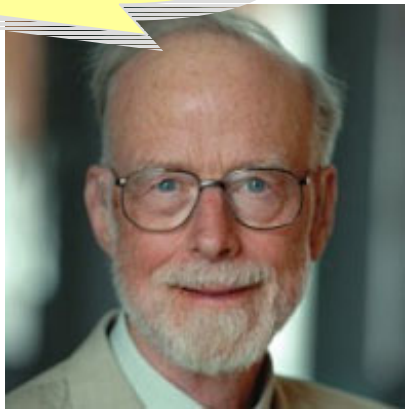

- Entstehung
  - 1960 waren noch keine schnellen Sortieralgorithmen bekannt.
  - man versuchte damals Sortierverfahren durch raffinierte Assemblerprogrammierung zu beschleunigen.

- Quick-Sort mit naheliegenden Verbesserungen ist
  - einer der schnellsten bekannten allgemeinen Sortieralgorithmen
  - theoretisch gut verstanden.

Hoare zeigte dadurch, dass es sinnvoll sein kann, nach **besseren Algorithmen** zu suchen, als vorhandene Algorithmen durch ausgefeilte Programmierung zu beschleunigen.

Quick-Sort

- Die Grundidee besteht darin, das vorgegebene Problem nach dem bereits genannten Motto Teile und Herrsche in einfachere Teilaufgaben zu zerlegen.
  - nehme irgendeinen Wert W der Teil von A ist – zum Beispiel den mittleren
  - konstruiere eine Partitionierung des Sortierfeldes **A** in Teilmengen $\mathbf{A}_1$ und $\mathbf{A}_2$ mit folgenden Eigenschaften:

  - $A = \mathbf{A}_1 \cup \mathbf{A}_2 \cup \{W\}$
  - Alle Elemente von $\mathbf{A}_1$ sind $\leq W$ (aber noch evtl. unsortiert).
  - Alle Elemente von $\mathbf{A}_2$ sind $\geq W$ (aber noch evtl. unsortiert).

Wenn jetzt $\mathbf{A}_1$ und $\mathbf{A}_2$ sortiert werden, ist das Problem gelöst.

Quick-Sort

```
Methode Sortiere (A){
     Konstruiere die Partition A = A1 W A2;
     Sortiere A1;
     Sortiere A2;
 }
```

noch zu lösendes Problem:

- finden eines Wertes W, so dass $\mathbf{A_1}$ und $\mathbf{A_2}$ möglichst gleich gross sind.

Quick-Sort

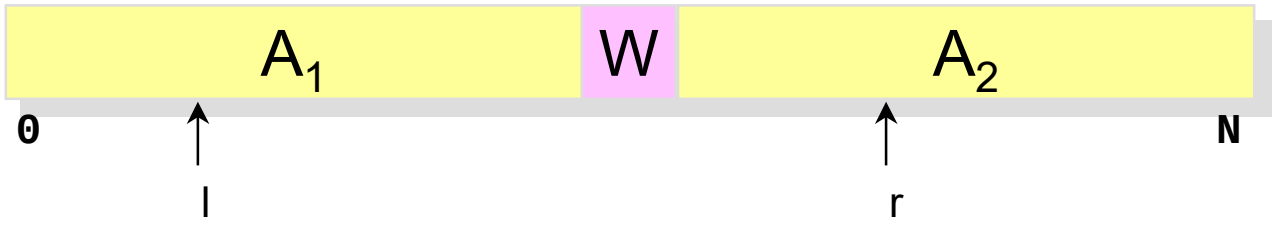

- Die Konstruktion der Partition erfolgt durch:
  - wähle ein Element W
  - suche von links ein Element, das auf falscher Seite ist, d.h. A[l] ≥ W
  - suche von rechts ein Element, das auf falscher Seite ist, A[r] ≤ W
  - vertausche von A[l] und A[r]
  - wiederhole obige Schritte bis l und r sich kreuzen, d.h. l ≥ r.

Aufgabe

Führen Sie die erste Partionierung mit dem Algorithmus auf der vorhergehenden Seite an dem folgenden Beispiel durch.

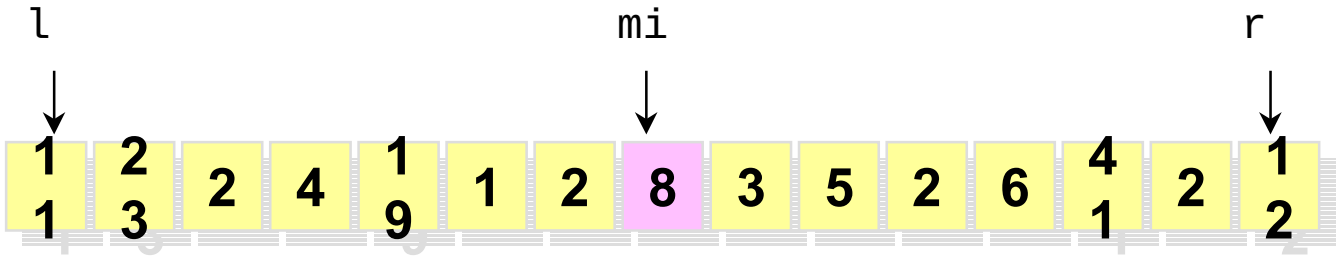

Quick-Sort: Wahl des Pivots

- Bestimmen des genau Median Wertes aufwendig -> Laufzeitvorteil von QuickSort ginge wieder verloren

W wird lediglich geschätzt

- folgende Pivotwahlen sind möglich
  - A[l] das (der Position nach) linke Element von A;
  - A[r] das (der Position nach) rechte Element von A;
  - A[mid] das (der Position nach) mittlere Element von A mit mid = (l+r)/2

- Strategie 1: nehme eines der drei Elemente
- Strategie 2: nehme das (wertmässig) mittlere der drei Elemente
- Strategie 3: nehme das arithmetisch Mittel der drei Elemente

Schlechte Pivotwahl

- Gutes Pivot-Element ist nicht unbedingt das Element, welches der Position nach in der Mitte liegt.

- die Möglichkeit einer ungünstigen Verteilung der Daten:
  - durch die Partitionierung in eine Hälfte der Partition sehr viele und in die andere Hälfte sehr wenige Daten gelangen. Bei unserem Beispiel ergibt sich folgende Situation:

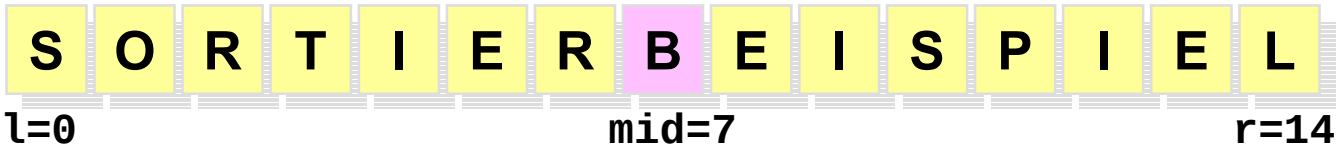

- Bei der Wahl von A[mid] als Pivot-Element ergibt sich ungünstige Partitionierung:

  A_1 ist leer und A_2 ist gerade mal ein Element kleiner als A.

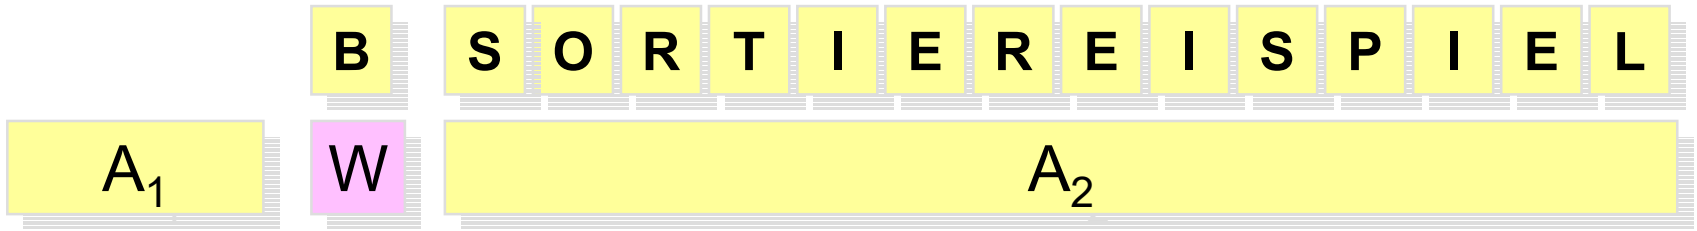

Quick-Sort: Wahl des Pivots

- W wird auch Pivot genannt
  - von entscheidender Bedeutung für die Effizienz von QuickSort.
  - optimal wäre ein Element, das A in **zwei gleich grosse Teile** partitioniert.

- W muss so bestimmt werden, dass gleich viele Werte grösser wie kleiner als W sind.

- Vorsicht: ist i.A. nicht gleich dem Mittelwert: $\sum x / n$

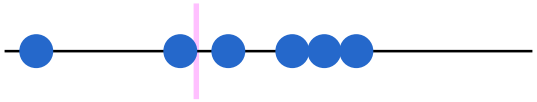

Aufgabe: Anwendung Median, Mittelwert

- Ein Lehrer möchte, dass der Schnitt einer Prüfung genau 4 beträgt. Welche Punktzahl muss er für eine 4 fordern; Punktedurchschnitt 5.25.

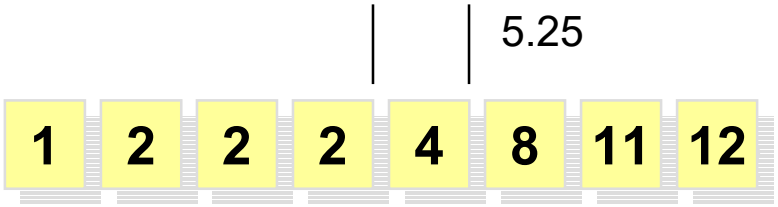

- Ein anderer Lehrer möchte, dass lediglich die Hälfte der Schüler eine genügende Note bekommt. Welche Punktzahl muss er jetzt für eine 4 fordern (ohne Runden)**.

* natürlich wird ein Lehrer das nie so machen. Noten werden immer gerecht vergeben und anhand eines vorher festgelegten Bewertungsmassstabes bestimmt.

** spätestens jetzt dürfte klar sein, dass das Beispiel völlig aus der Luft gegriffen ist und absolut keinen Bezug zur Realität hat.

Pivotwahl nach sog. Median Methode

- Die drei Elemente A[l], A[mid] und A[r] werden vorsortiert und man nimmt das dem Werte nach **mittlere dieser drei Werte**.

vorsortieren:

```
int mid = (l+r)/2;
if (a[l]   > a[mid]) swap(a, l, mid);
if (a[mid] > a[r])   swap(a, mid, r);
if (a[l]   > a[mid]) swap(a, l, mid);
int p = a[mid];
if (r-l > 2) {...
```

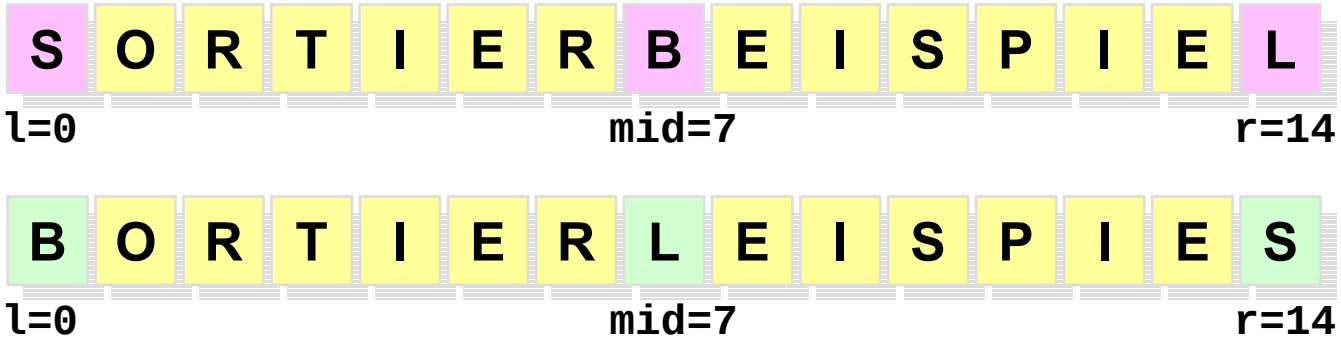

Partition mit Median Methode

- Dadurch ergibt sich eine bessere Pivot Wahl und ausgeglichenere Hälften

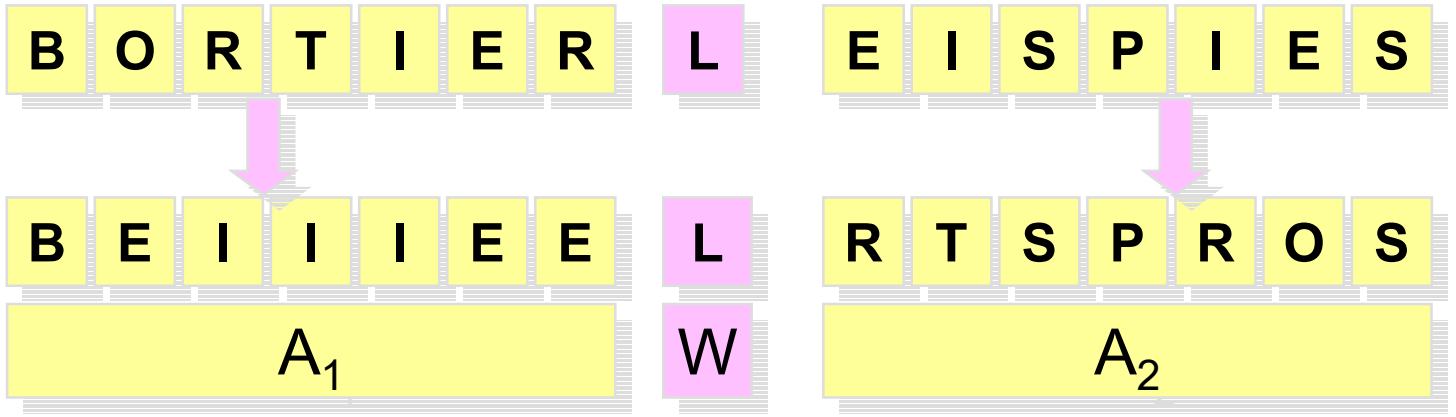

`mid=7`

- Optimale Partionierung erreicht
  - **15** Elemente aufgespalten in zwei Partitionen mit je **7** Elementen
  - muss aber nicht immer so sein

Partition Methode

- teile den Bereich in zwei "alle kleiner" und "alle grösser" als Pivot
- gebe Index der Grenze zurück

```
public static int partition (int[] a, int left, int right) {
       int pivot = arr[(left + right) / 2];
       while (left <= right) {
              while (arr[left] < pivot) {
                     left++;
              }
              while (arr[right] > pivot) {
                     right--;
              }
              if (left <= right) {
                     swap(a,left,right);
                     left++;
                     right--;
              }
       }
       return left;
    }
```

finde linkes Element grösser Pivot

finde rechtes Element kleiner Pivot

schon gekreuzt?

index der neuen Grenze

Quick-Sort

- die eigentliche Sort Methode ist rekursiv

```
void quickSort(int[] a, int left, int right) {
    if (left < right) {
        int l = partition (a,left,right);
        quickSort(arr, left, l-1);
        quickSort(arr, l , right);
    }
}

public void quickSort(int[] a){
  quickSort(a, 0, a.length-1);
}
```

Quick-Sort: Aufwand

- ein Bereich muss $\log_2(N)$ mal geteilt werden:
  - Es entsteht dabei ein binärer Partitionenbaum mit Tiefe **$\log_2(N)$**.
  - Der Aufwand, auf jeder Schicht diese komplett zu partitionieren, ist proportional zu **N**.
- der Gesamtaufwand ist somit proportional zu **$N \times \log_2(N)$**.

- Die Ordnung von Quicksort ist somit **$O(N \times \log(N))$**,
  - wenn bei jeder Partitionierung eine gleichmässige Aufteilung der Daten erfolgt

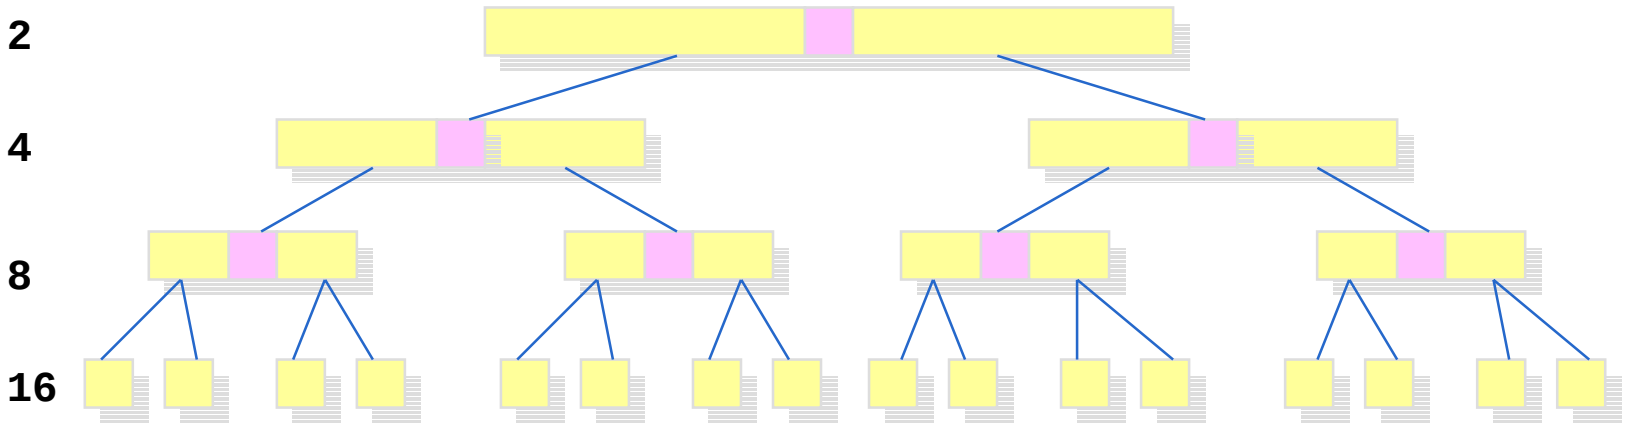

Quick-Sort: Aufwand

- ungünstigster Fall:
  - jeder Partitionierungs-Schritt nur jeweils das Vergleichselement
  - -> Baum wird zu Kette (Liste) mit N Elementen: man sagt auch der Baum **entartet** oder **degeneriert**

- In diesem Fall ist der Aufwand proportional zu $O(N^2)$.

- Dies tritt jedoch nur in extra konstruierten Fällen auf
- Im Normalfall ist die Partitionierung bei QuickSort nahezu optimal

QuickSort immer die **erste Wahl**, wenn grösserer Mengen ungeordnete Daten sortiert werden müssen.

Distribution Sort

Distribution-Sort

- Die bisher diskutierten Sortieralgorithmen basieren auf den Operationen: Vergleichen zweier Elemente und ev. Vertauschen zweier Elemente (swap).
- Im Gegensatz dazu kommt Distribution-Sort **ohne Vergleiche** aus.
- Die zu sortierenden Elemente werden
  - entsprechend dem Sortierschlüssel in Fächer verteilt: O(n)
  - zusammengetragen: O(n)
- Bsp: Briefe werden in die entsprechenden Fächer nach Plz. sortiert.

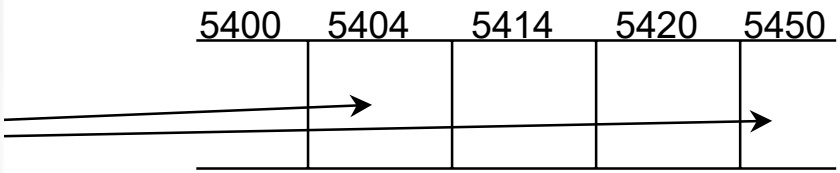

Distribution-Sort Beispiel: Plz Regionen

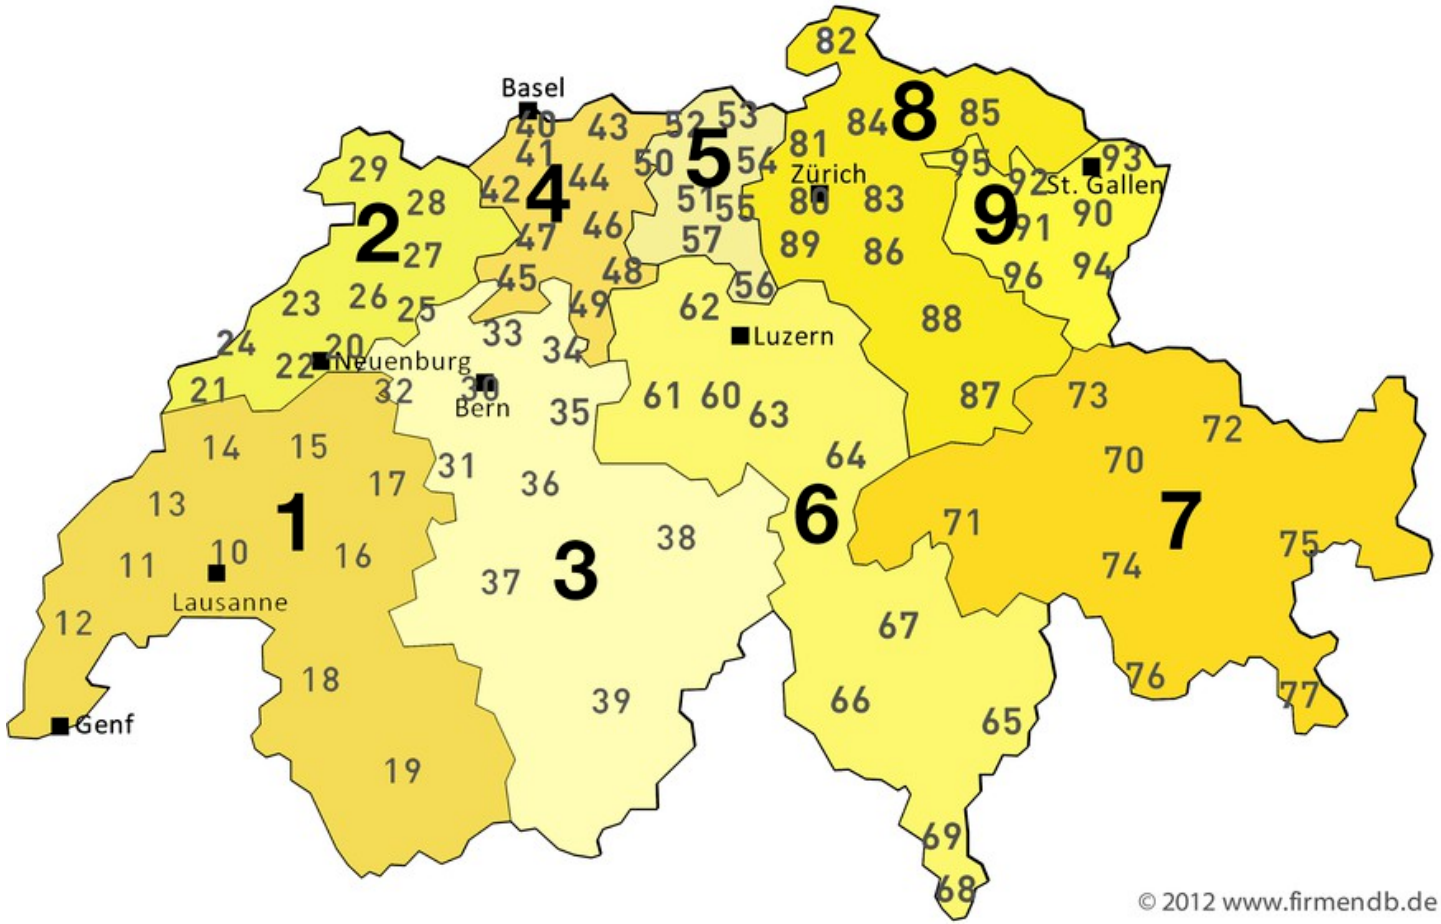

Distribution-Sort Beispiel: alte AHV Nummer

School of Engineering

AHV Nummer

Das 900-teilige Alphabet

A	**100**	Ald	**107**	Ams	**114**	Arno	**121**
Abi	**101**	All	**108**	An	**115**	Aro	**122**
Abl	**102**	Alm	**109**	Ando	**116**	As	**123**
Ac	**103**	Am	**110**	Ane	**117**	Au	**124**
Af	**104**	Amd	**111**	Ann	**118**		
Ag	**105**	Amm	**112**	Ao	**119**		
Al	**106**	Amo	**113**	Ar	**120**		
B	**125**	Berh	**157**	Bom	**189**	Brund	**221**
Bach	**126**	Bern	**158**	Bon	**190**	Brunn	**222**
Bachm	**127**	Berne	**159**	Boo	**191**	Bruno	**223**
Bad	**128**	Bero	**160**	Bor	**192**	Bruo	**224**
Bag	**129**	Bert	**161**	Borg	**193**	Bu	**225**
Bal	**130**	Bes	**162**	Born	**194**	Buch	**226**
Ball	**131**	Beu	**163**	Bos	**195**	Buchi	**227**
Balm	**132**	Bf	**164**	Boss	**196**	Bucho	**228**
Bals	**133**	Bi	**165**	Bossh	**197**	Buci	**229**

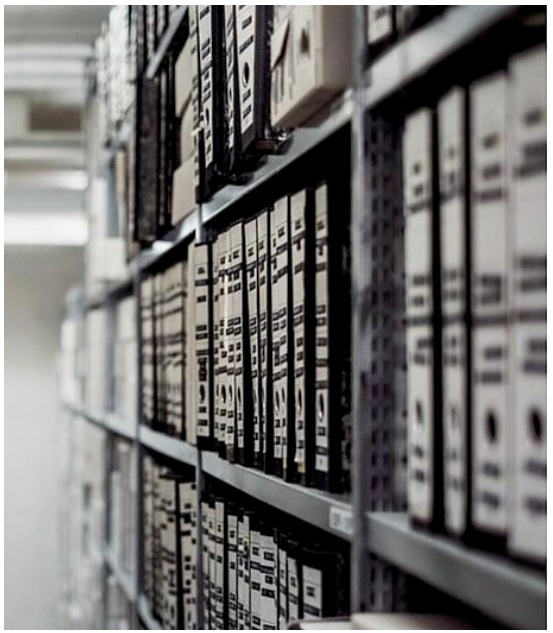

https://www.ahvnummer.ch/900alpha.htm

Distribution-Sort Beispiel

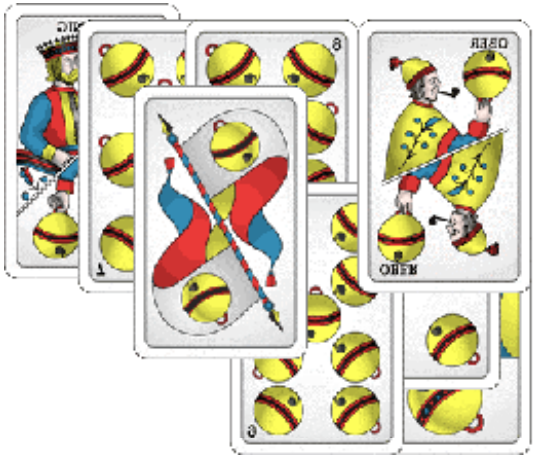

direktes Einfügen

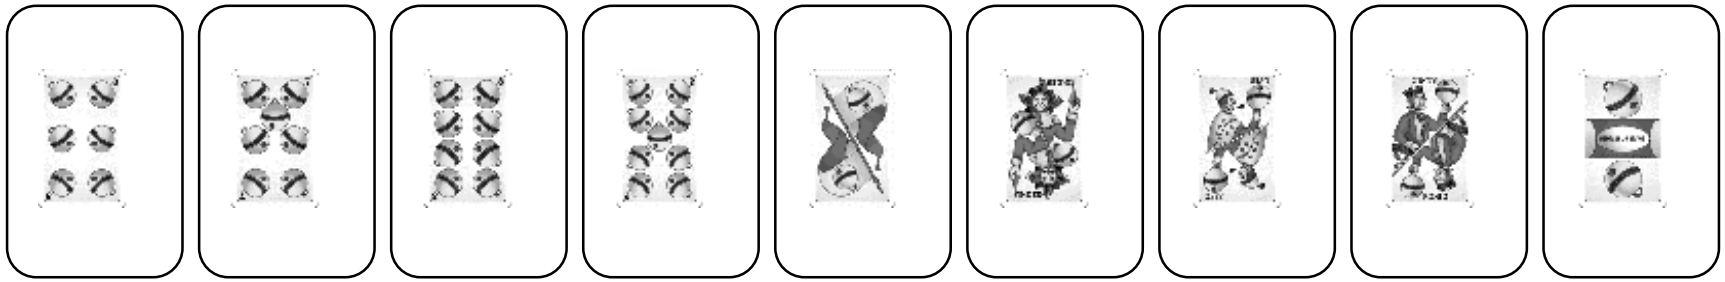

Distribution-Sort

- Grundprinzip wie beim direkter Adressieren (vergl. Hashtable):

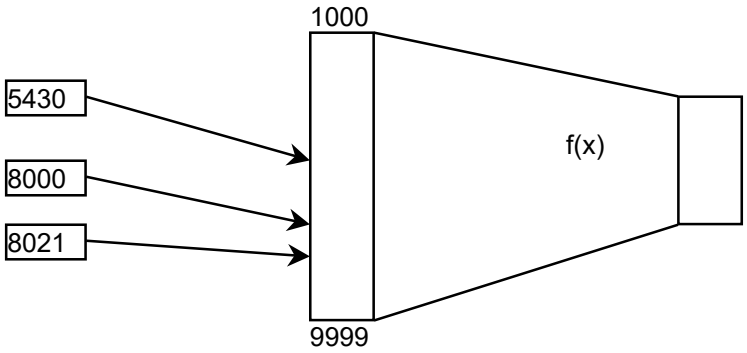

- Vorteile
  - schneller geht's nicht
  - linearer Algorithmus: die Komplexität ist also O(N)
- Nachteile
  - Verfahren muss an den jeweiligen Sortierschlüssel angepasst werden.
  - Geht nur bei Schlüsseln, die einen kleinen Wertebereich haben oder auf einen solchen abgebildet werden können, ohne dass die Ordnung verloren geht.
  - Allgemeines Hashing funktioniert nicht: wieso?
- Distribution-Sort mit Abstand der schnellste Algorithmus zum Sortieren.
  - Es handelt aber nicht um ein allgemein anwendbares Sortierverfahren.

Laufzeitvergleich schneller Sortieralgorithmen

Laufzeitvergleich schneller Sortieralgorithmen

Laufzeitmessung bei zufällig sortierten Daten

	N=10000	N=20000	N=30000	N=40000
Quick	1.57	3.38	5.21	7.19
Distribution	1.2	2.4	3.6	4.8

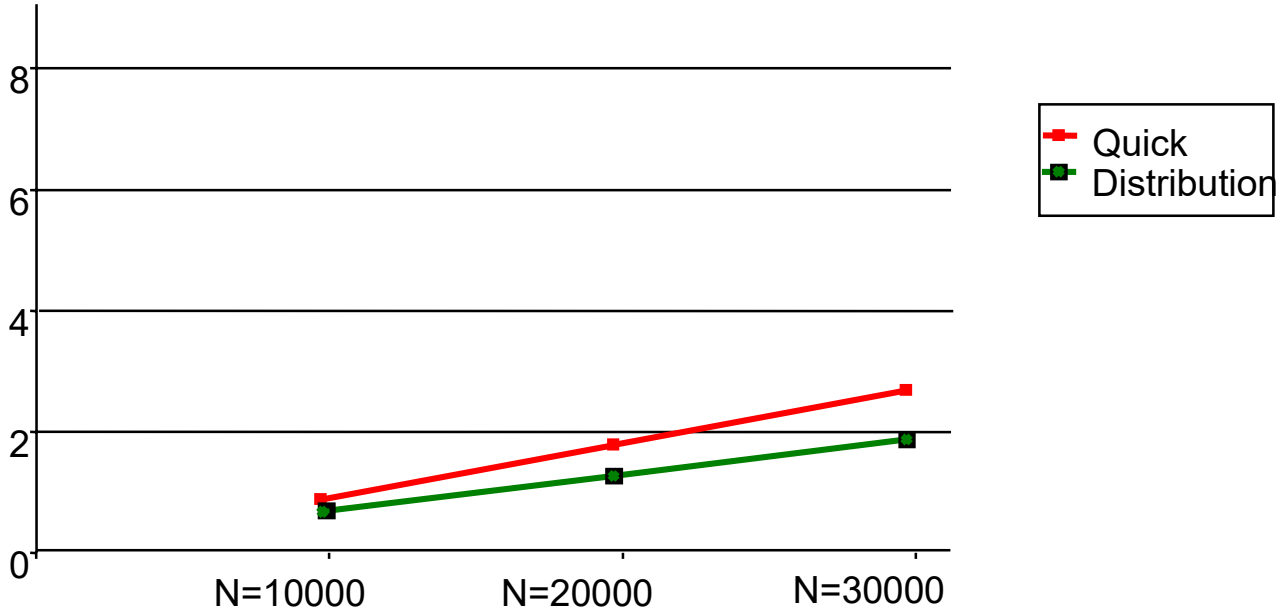

Vorsortierte Daten

School of Engineering

- Bei vorsortierten Daten:

	N=10000	N=20000	N=30000	N=40000
Quick	0.48	1.02	1.43	2.16
Distribution	1.2	2.4	3.6	4.8

- In der Praxis recht häufig
  - unsortierter Datenbestand wird einmalig eingebracht.
  - danach ändern sich in dem Datenbestand jeweils nur wenige Datensätze:
    - *einige wenige Datensätze werden neu eingebracht.*
    - *einige wenige Datensätze werden geändert oder gelöscht.*
- Es kann sich sogar lohnen, den Datenbestand auf die Sortiertheit vorab zu überprüfen.

Bei vorsortierten Daten ist der Insertionsort am schnellsten

Übung

- Ein O(n*log n) Sortieralgorithmus brauche 1 Sekunde für 10’000 Elemente; wie lange braucht er für 100'000 Elemente?
  - es soll nur der erste Koeffizient betrachtet werden.

Optimalitätssatz für Sortieralgorithmen

Satz: Ein Sortieralgorithmus, der darauf beruht, dass Elemente **untereinander verglichen** werden, kann bestenfalls eine Komplexität von $O(n \times \log(n))$ im Worst Case haben.

- Distribution-Sort fällt nicht darunter, da er
  - **nicht** auf dem Vergleich von Elementen untereinander beruht.
  - auf **Verteilen** und **Zusammentragen** von Datensätzen mit Hilfe von Fächern basiert.

Externe Sortierverfahen

Externen Sortierverfahren: 2 Phasen Sortieren

School of Engineering

- Beim externen Sortieren liegen die Daten in einer Datei auf der Festplatte. Zwei Arten des Zugriffs sind möglich:
  - sequentieller Zugriff
  - der beliebig auf die Element wäre zwar möglich, ergebe aber einen grossen Effizienzverlust (siehe Vorlesung BS)

- Annahmen:
  - Datenstrom der sequentiell gelesen wird
  - Jeweils nur ein Teil der Daten passen in den Hauptspeicher

1. Phase: Sortieren-Verteilen

- lade jeweils einen Teil des Datei in den Speicher
  - sortiere diesen Teil mit schnellem internem Verfahren
  - schreibe sortiere Abschnitte in mehrere (mindestens zwei) Ausgabedateien
  - es entstehen Folgen von sortierten Abschnitten in den Ausgabedateien

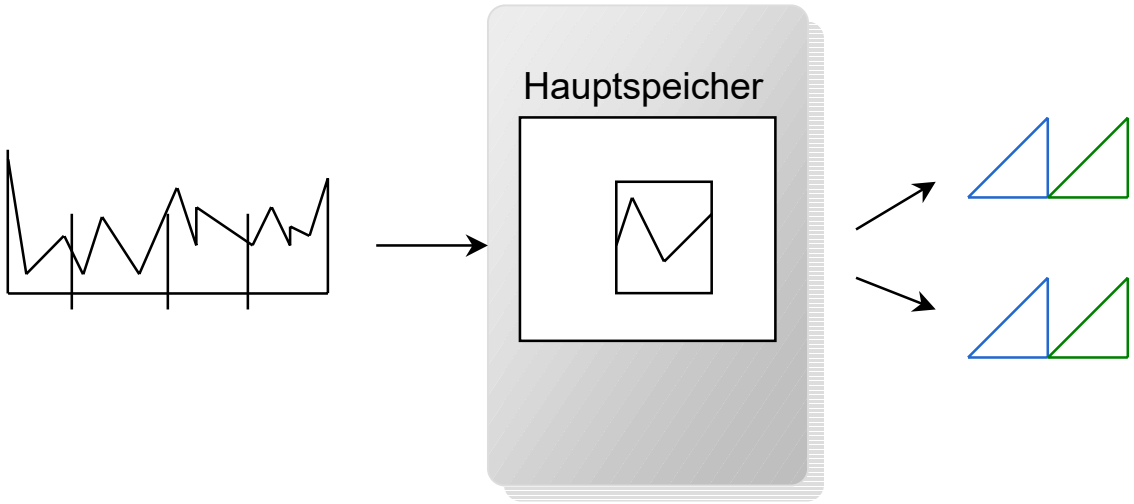

2. Phase: Mischen

- 2. Phase: Mischen
  - lese von beiden Dateien das erste Element
  - schreibe das kleinere und lese das nächste von der gleichen Datei

- -> Länge der geordneten Abschnitte hat sich verdoppelt
  - ouput -> input
  - solange wiederholen, bis vollständig sortiert

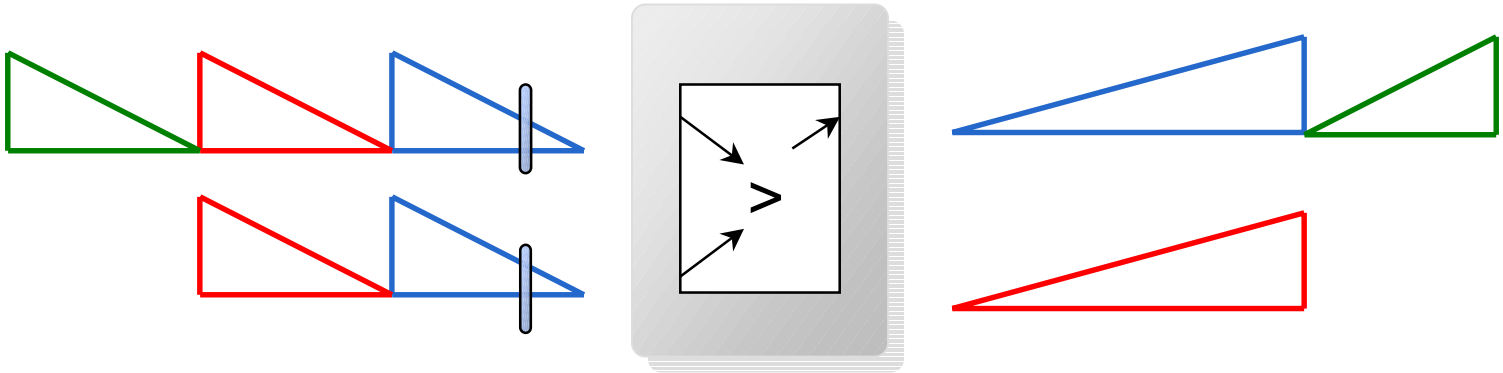

Beispiel Jasskarten

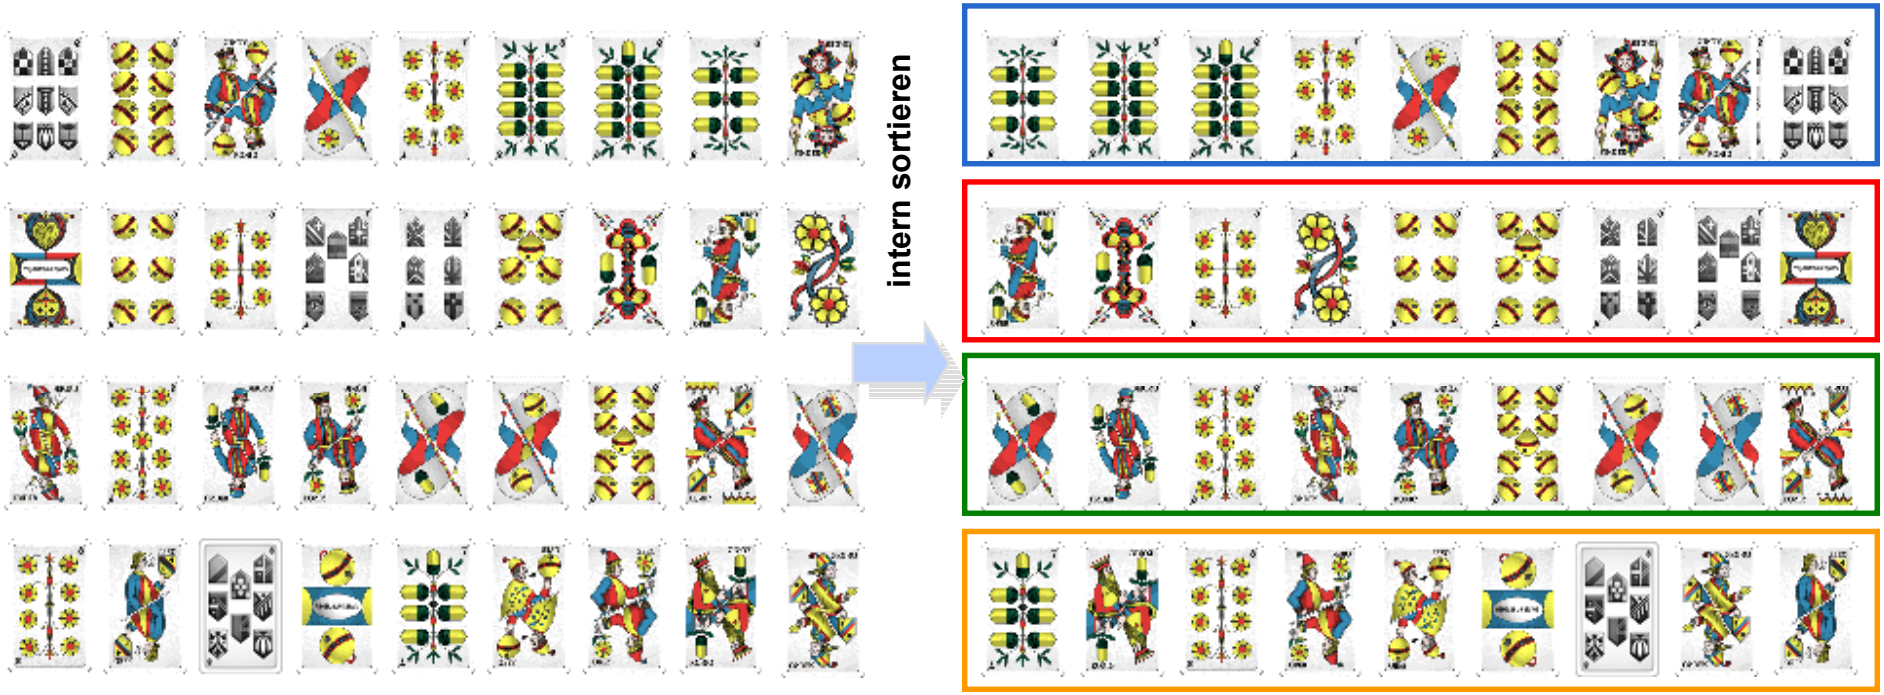

Misch Durchgang 1

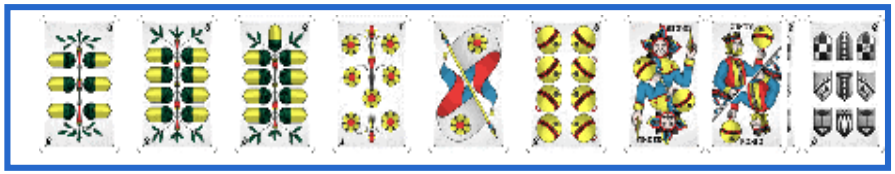

mischen

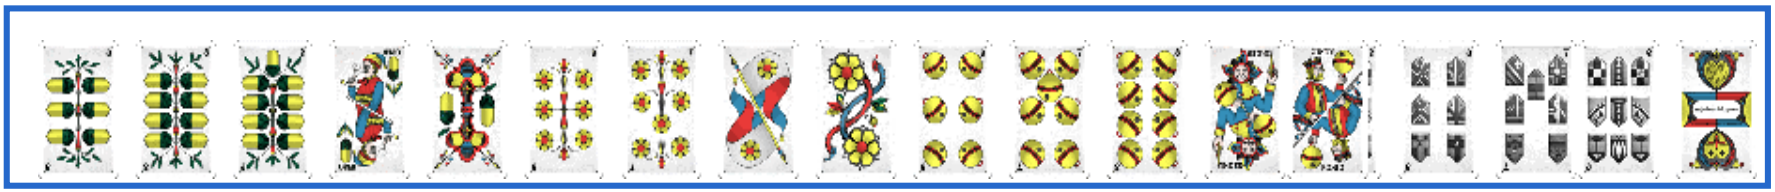

mischen

Misch Durchgang 2

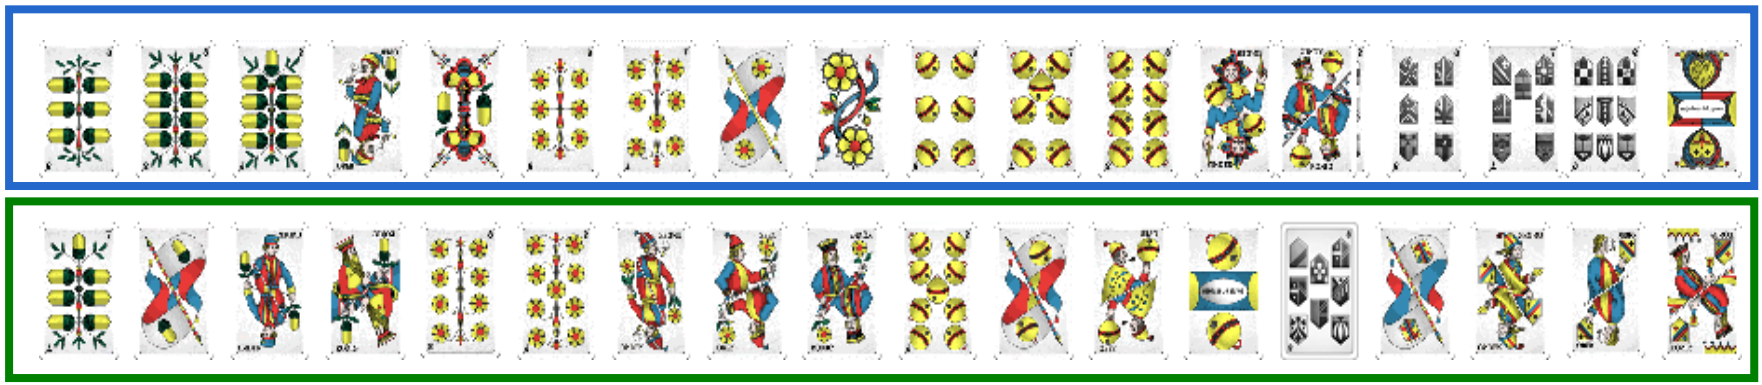

mischen

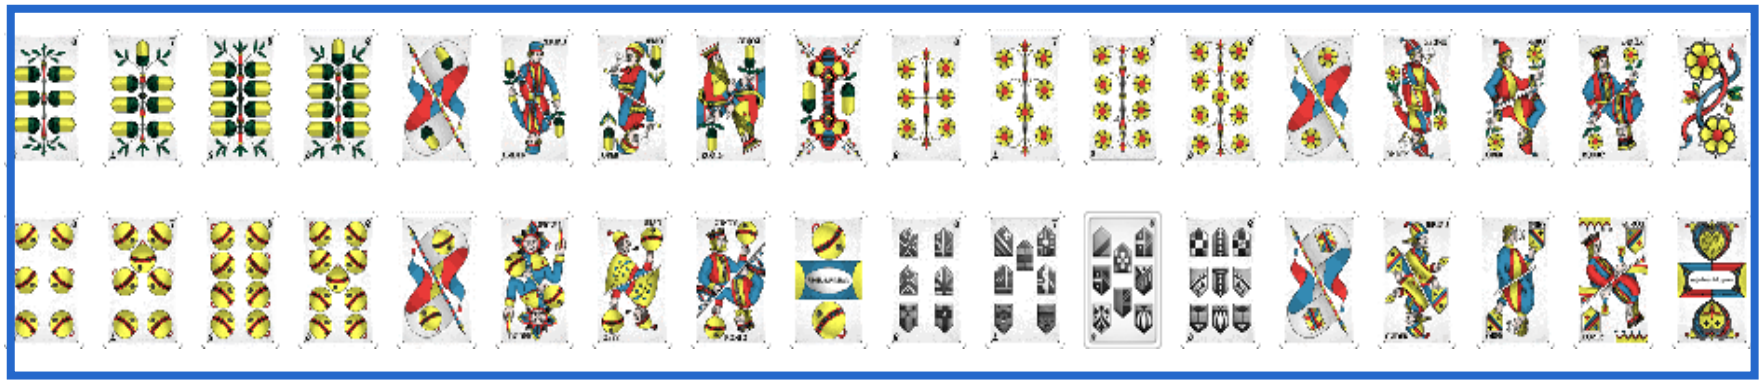

Laufzeit

- Annahme:
  - Zeit für internes Sortieren kann vernachlässigt werden
  - Beispiel 16 Sequenzen, 2 Eingabe und 2 Ausgabe Dateien

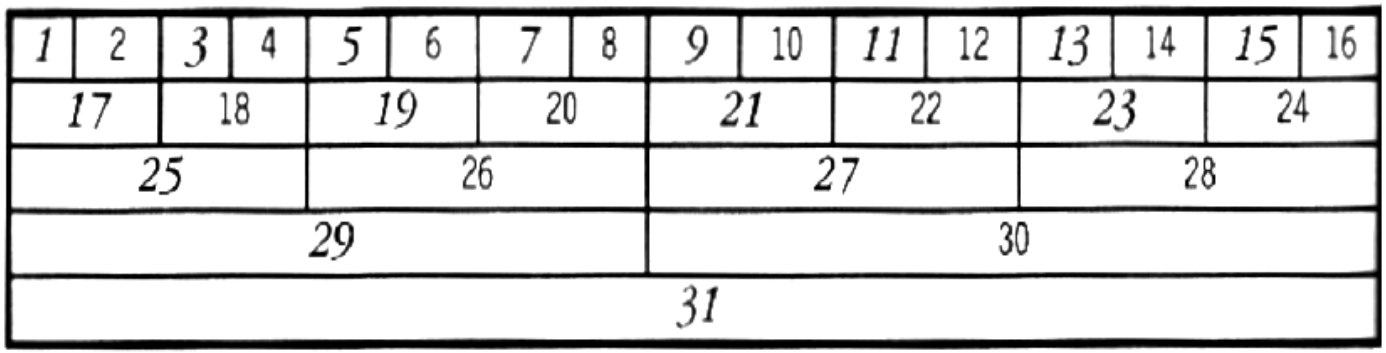

- Generell:
  - *bei n Sequenzen und m Eingabedateien*
  - *# Mischphasen* $\lfloor log_m\, n \rfloor$
  - *Aufwand von Mischen* $n * \lfloor log_m\, n \rfloor$

Wahl des Sortierverfahrens

Wahl des Sortierverfahrens

- **Internes oder externes Verfahren**
  - Sortieren im Hauptspeicher
  - Sortieren im Hauptspeicher und Sekundärspeicher (Platte)

- **Methode des Algorithmus:**
  - Vertauschen
  - Auswählen
  - Einfügen
  - Rekursion
  - Verteilen
  - Mehrphasen: Sortieren-Mischen

Wahl des Sortierverfahrens

- Nach Effizienz:
  - Laufzeit: $O(n^2)$ oder $O(n \times \log n)$ oder sogar $O(n)$
  - Speicherbedarf: Wieviel Speicher wird zusätzlich zu dem für die zu sortierenden Daten benötigt?

- Allgemein / mit speziellen Voraussetzungen:
  - allgemein: Benötigt nur Schlüsselvergleiche
  - allgemein: Ändern der Reihenfolge oder Angabe der Reihenfolge
  - allgemein: Wird die Reihenfolge von Datensätzen mit gleichem Sortierkriterium durch den Algorithmus geändert? →Stabilität
  - speziell: Der Algorithmus setzt eine bestimmte Struktur der Schlüssel voraus.

Wahl des Sortierverfahrens

School of Engineering

- Bibliotheksfunktion -> Collections.sort oder Arrays.sort
- wenige Datensätze (weniger als 1000),
  - Laufzeit unerheblich,
  - möglichst einfachen Sortieralgorithmus wählen (also Insertion-Sort, Selection-Sort oder Bubble-Sort).
- vorsortierte Datenbestände
  - dann Insertion- oder Bubble-Sort .
- viele ungeordnete Daten
  - dann Quick-Sort bevorzugen.
- viele Daten, ungeordnet, sehr oft zu sortieren
  - Distribution-Sort an das spezielle Problem anzupassen
- sehr viele Daten
  - externes Sortierverfahren in Kombination mit schnellem internem

Optimierung durch Kombination von Algorithmen

Optimierungen von Quicksort

- QuickSort ist schnell, aber wegen der Rekursion hat er einen relativ grossen initialen Aufwand: *"Footprint"*
- Für wenige (~10..100) zu sortierende Daten ist ein einfaches Sortierverfahren schneller.
- Idee: ab einer bestimmten Länge des Intervalls nicht mehr QuickSort verwenden sondern z.B. InsertionSort; bringt ca.10%

```
  static void quickerSort(int[] a, int left, int right) {
    if (right - left < QSTHREASHHOLD)
        insertionSort(a, left, right);
    else {
        int l = partition (a,left,right);
        quickerSort(arr, left, l-1);
        quickerSort(arr, l , right);    }
}
```

z.B. 50

Optimierung durch Parallelisierung

Speed vs. Power Consumption

- Das grösste Problem heute ist die Wärmeabgabe der Chips
- Jeder CMOS Schaltvorgang braucht Energie, Verkleinerungen erhöht die Leckströme
- Die Energiedichte innerhalb einer CPU ist grösser als diejenige im Kern eines Kernreaktors
- Computer Industrie ist für 2% der weltweiten CO_2 Emissionen verantwortlich
- Rechenzentren: Stromkosten p.a. ~ HW Kosten

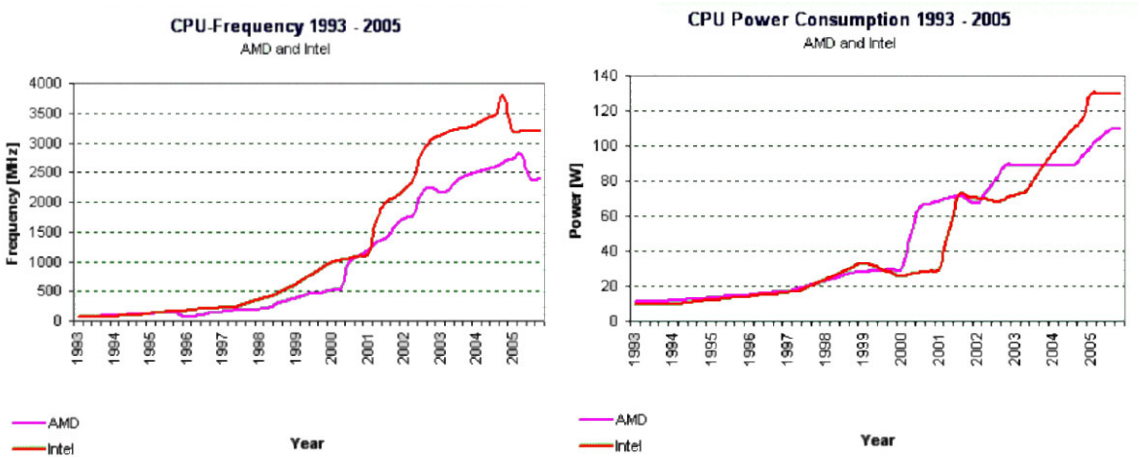

Beschleunigung durch Parallelisierung

- Modern multicore CPUs sprechen eigentlich dafür aber
- Amdahl's Law
  - Die Geschwindigkeitssteigerung ist durch den sequentiellen Anteil im Programm limitiert

P: ist der Anteil des Programms, der parallelisiert werden kann

N: Zahl der Prozessoren

$$\text{Speedup} = \frac{1}{(1-P) + \frac{P}{N}}$$

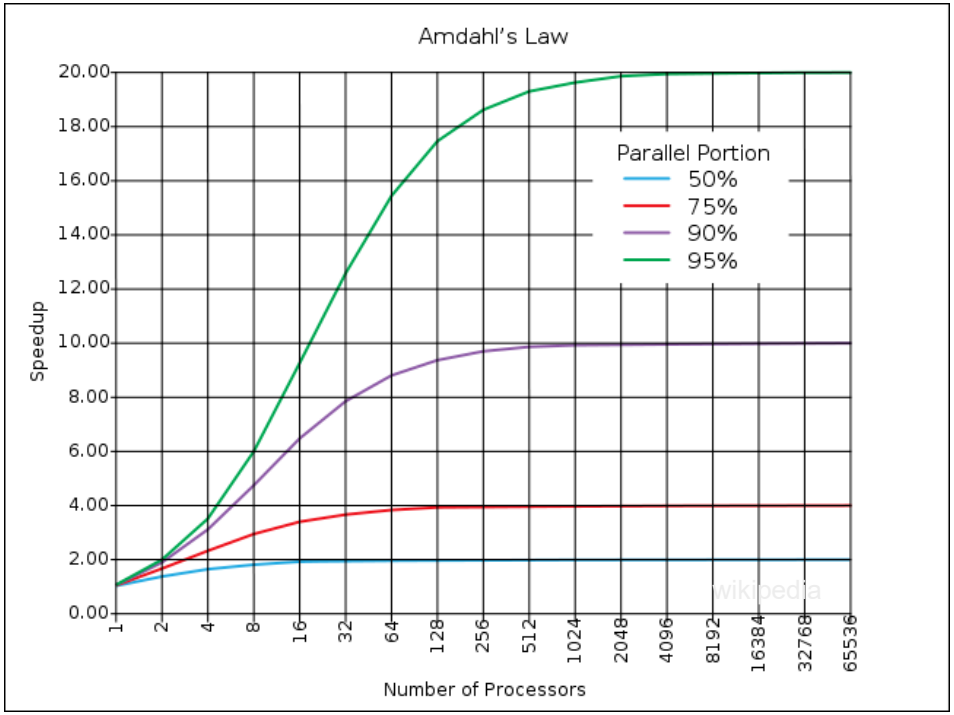

- Es kommt aber noch ein Overhead durch die Steuerung der Threads

Zugriff auf den Hauptspeicher

- Zugriffszeiten

register:	<	1 clk
L1:	~	4 clks
L2:	~	11 clks
L3:	~	40 clks
main memory:	~150-300 clks	

- Hauptspeicherzugriff ist im Vergleich zum Cache sehr teuer

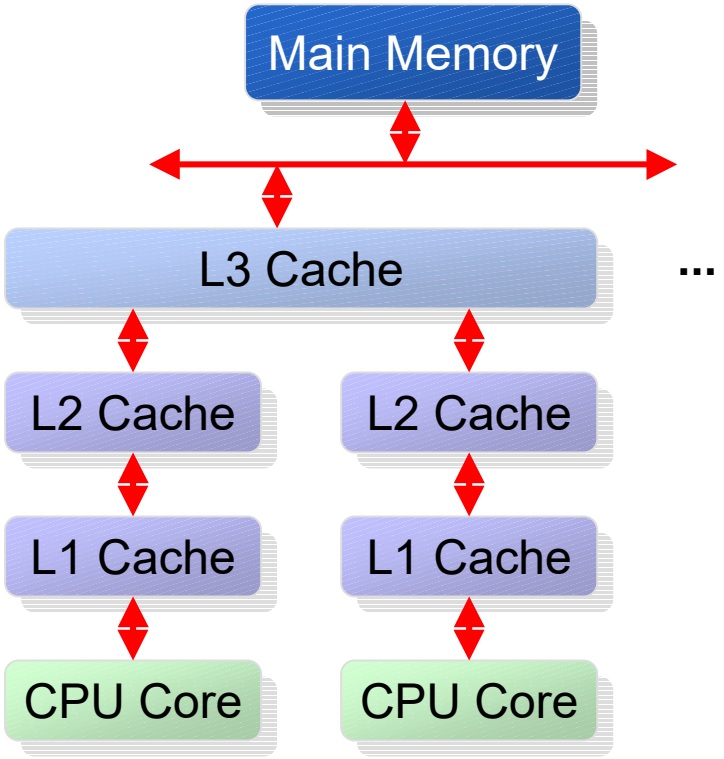

Java Memory Modell

- JMM abstrahiert von physikalischem Memory Modell
- Alle Threads teilen Hauptspeicher
- Jeder Thread hat einen lokalen Arbeitsspeicher
- Veränderungen aus lokalem (Thread-) Arbeitsspeicher werden nur zurückgeschrieben
  - Bei expliziter Synchronisation
  - Thread Start und Beendigung
  - Lesen/Schreiben von *volatiles*
  - Erstes Lesen von *finals*

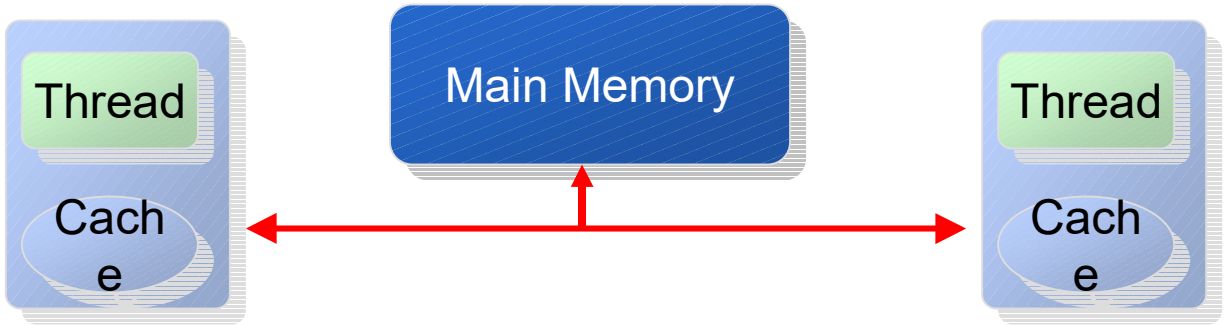

Prozessor Auslastung

- Single Threaded

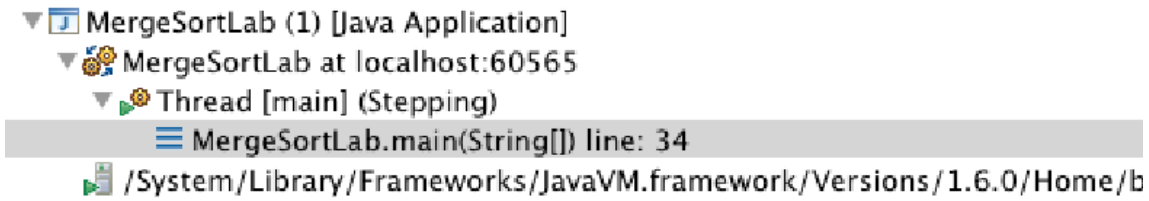

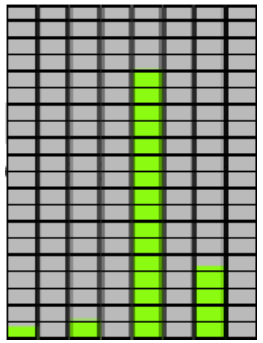

- Multithreaded

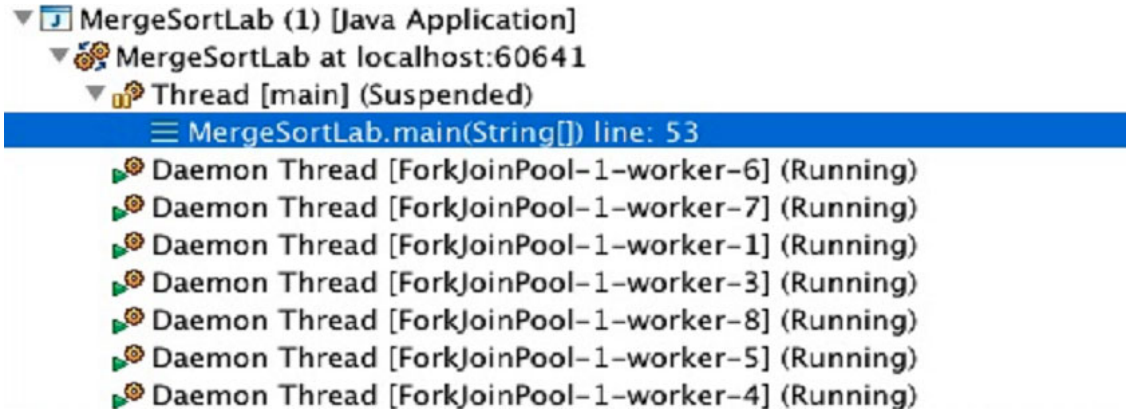

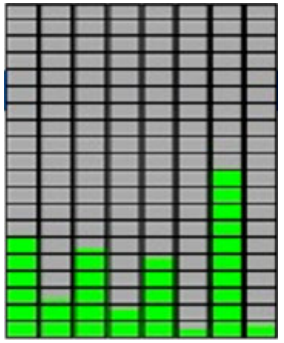

NaiveParallelQuickSort

School of Engineering

```
class NaiveParallelQuickSort extends Thread {
.....

     public NaiveParallelQuickSort(int[] a, int left, int right) {
        thia.a = a; ...

     public static void sort(int[] a) {
        Thread root = new Thread(new NaiveParallelQuickSort(a, 0, a.length - 1));
        root.start();
        root.join();
     }

     public void run() {
        int l = 0;
        Thread t1 = null;
        Thread t2 = null;

        if (left < right) {
            l = partition(a, left, right);
            t1 = new NaiveParallelQuickSort(a, left, l-1);
            t1.start();
            t2 = new NaiveParallelQuickSort(a, l , right);
            t2.start();
            if (t1 != null) t1.join();
            if (t2 != null) t2.join();
        }
     }
```

Als separater Thread

private int[] a;
private int left;
private int right;

Setzen der Parameter

Parallele Threads starten

Warte bis beendet

Ein neuer Thread pro Task

- Je ein neuer Thread für jede Partitionsaufgabe
- Java Threads werden auf Betriebssystems Threads abgebildet: "Kernel Level Threads"
- Vorteile
  - Die Rechenzeitzuteilung kann besser (von BS) verwaltet werden
  - Sind mehrere CPU-Kerne/Proz. im Rechner vorhanden, können diese ausgenutzt werden
- Aber
  - Erzeugung und Zerstörung von Threads kostet (viel) Zeit
  - Instanziierte Threads belegen Speicher
  - Ineffektiv, mehr Threads zu erzeugen, als die Prozessoren gleichzeitig handhaben können, da immer einige inaktiv (idle) sein werden

NaiveParallelQuickSort erste Korrektur


```
class NaiveParallelQuickSort extends Thread {
      .....
      private final int SPLIT_THRESHOLD = 100000;

      public void run() {
         int l = 0;
         Thread t1 = null;
         Thread t2 = null;

         if (left < right) {
              l = partition(a, left, right);
              if (l - left > SPLIT_THRESHOLD) {
                 t1 = new NaiveParallelQuickSort(a, left, l-1);
                 t1.start();
              } else {
                 QuickSort.sort(a, left, l-1);
              }
              if (right - l > SPLIT_THRESHOLD) {
                 t2 = new NaiveParallelQuickSort(a, l , right);
                 t2.start();
              } else {
                 QuickSort.sort(a, l , right);
              }
              if (t1 != null) t1.join();
              if (t2 != null) t2.join();
         }
}
```

Nur wenn Task genügend gross parallel ausführen

Sonst sequentiell

Threadpools

Idee der Thread Pools

- Es wird einer gewissen Anzahl von einmal gestarteten Threads (Pool von Threads) immer wieder eine neue Aufgabe (Tasks) übergeben.
- Pool Size entspricht in etwa der Anzahl Rechnerkerne
  - bei I/O Intensiven mehr, da immer ein Teil wartend/blockiert ist.

```
java.lang.Runtime.getRuntime().availableProcessors()
```

- Die Reihenfolge der Abarbeitung der Tasks wird durch eine Ausführungs-strategie bestimmt

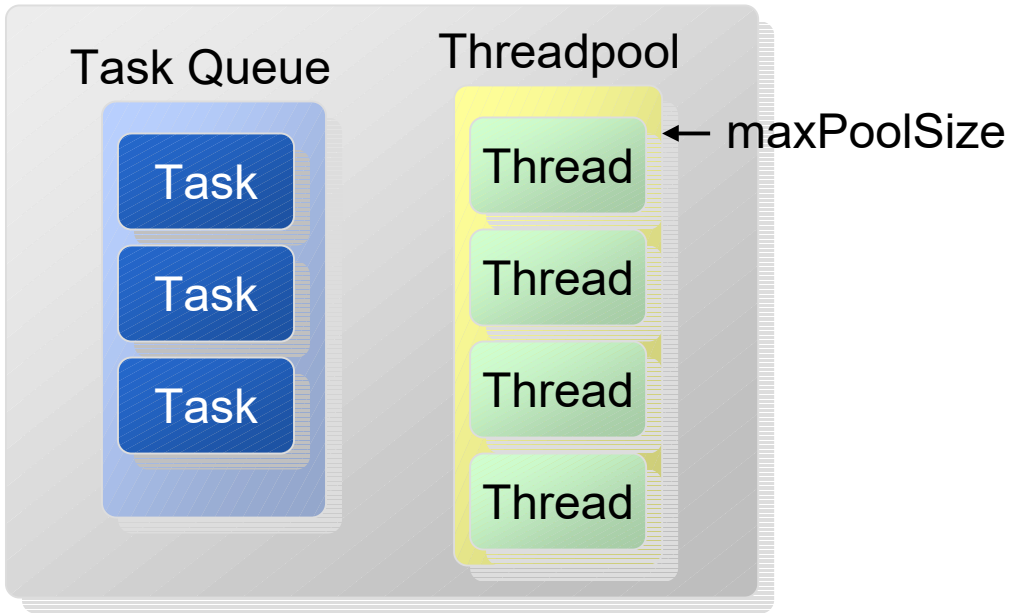

Ausführungsstrategien

- bessere Kontrolle über Ressourcen durch Einhaltung einer Ausführungsstrategie
  - in welchem Thread wird ein Task ausgeführt
  - in welcher Reihenfolge werden die Tasks ausgeführt (LIFO, FIFO, priorisiert, ...)
  - Anzahl der Tasks gleichzeitig ausgeführt werden dürfen
  - Anzahl der Tasks die auf Ausführung warten dürfen
- Mögliche Ausführungsstrategien:
  - Begrenzung der Thread-Anzahl
  - Caching von Threads
  - Queueing von Tasks
- Auswahl effektivster Policy hängt vom Anwendungsfall ab

Java Implementation

- ExecutorService Interface für ThreadPools
- Java Executor (**`java.util.concurrency`**) stellt Framework zur Thread-Ausführung bereit, das verschiedene Ausführungsstrategien realisiert
  - verschiedene Varianten werden durch Factory-Methoden der Klasse **`Executors`** bereitgestellt

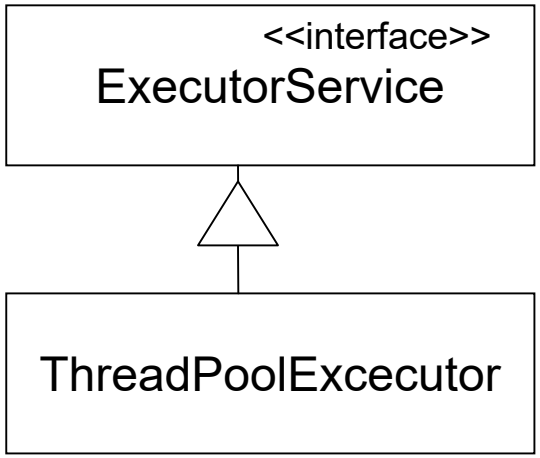

- FixedThreadPool
  - Pool mit fester Menge von Threads, die zur Ausführung eingereichter Tasks eingesetzt werden
- CachedThreadPool
  - Pool mit flexibler Menge von Threads, die sich an die Zahl der eingereichten Tasks anpasst
- SingleThreadExecutor
  - einzelner Thread, der eingereichte Tasks nacheinander (gemäß FIFO- oder LIFO-Prinzip oder nach Priorität) abarbeitet
- ScheduledThreadPool
  - Pool mit fester Menge von Threads, die zur zeitgesteuerten bzw. wiederkehrenden Ausführung eingereichter Tasks eingesetzt werden

Lebenszyklus des Threadpools

- Erzeugung via Fabrikmuster Methoden

```
threadPool = Executors.newFixedThreadPool(parallelism);
```

- Drei Zustände:
  - **running**
    - Threadpool nimmt Tasks entgegen und führt sie aus, sobald Threads verfügbar sind
  - **shutting down** – Varianten:

```
threadPool.shutdown();
```

    - graceful shutdown
      - Threadpool führt laufende und bereits angenommene, aber nicht begonnene Tasks noch aus, nimmt jedoch keine neuen Tasks mehr an
    - abrupt shutdown
      - Threadpool führt laufende Tasks noch aus, verwirft aber bereits angenommene, noch nicht laufende Tasks, und nimmt keine neuen Tasks mehr an
  - **terminated**
    - keine Tasks werden mehr ausgeführt oder angenommen

Einstellen eines Threads

- Einstellen eines Tasks in einen Threadpool

```
Future<V> submit(Runnable task)
Future<V> submit(Callable task)
```

Keine Rückgabewerte

Mit Rückgabewerten

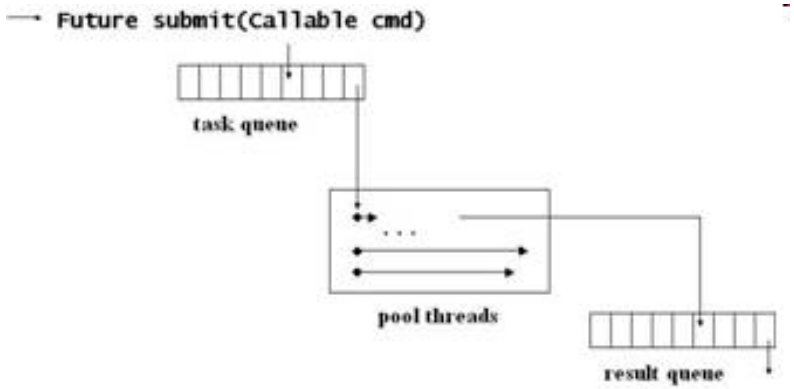

- Verwendung von Callable Interface wenn Rückgabewerte/Resultate benötigt werden

Resultat der Ausführung

- **Submit** des **`Runnable(oder Callable)`** in Threadpool liefert **`Future`**
  - mit **`get`**-Methode zur Abfrage des Rückgabewerts vom Typ **`V`**
    - *wartet, bis Rückgabewert feststeht*
    - *ggf. nur solange, bis angegebener Timeout erreicht*
  - mit **`cancel`**-Methode zur Stornierung der Aufgabe
    - *unmittelbare Streichung, wenn Bearbeitung noch nicht begonnen*
    - *Abbruchversuch, wenn schon in Bearbeitung*

```
public interface Future<V> {
 boolean cancel(boolean mayInterruptIfRunning);
 boolean isCancelled();
 boolean isDone();
 V get() throws InterruptedException, ExecutionException,
               CancellationException;
 V get(long timeout, TimeUnit unit)
     throws InterruptedException, ExecutionException,
            CancellationException, TimeoutException;
}
```

warte auf Beendigung des Tasks

Tasks mit Rückgabewerten

- Realisierung der Anwendungslogik mit Rückgabetyp **`V`** in der Methode **`call`** einer Implementierung des Interfaces **`Callable`** statt **`Runnable`**:

```
public interface Callable<V> {
    V call() throws Exception;
}
```

- Beispiel:

```
class Foo implements Callable<Integer> {
    ...
    public Integer call() {
            int result = ...;

           return result;
    }
}
```

Thread Safe Collections

- im Paket `java.util.concurrent` gibt es einige Thread Safe Collections
- Im Fall von erwarteter hoher Parallelität sollten diese genommen werden

```
ConcurrentHashMap<K,V>          // A hash table supporting full concurrency of
                                retrievals and
                                adjustable expected concurrency for updates

ConcurrentLinkedQueue<E>        // An unbounded thread-safe queue based
                                on linked nodes.

SynchronousQueue<E>             // A blocking queue in which each put must
                                wait for a take, and vice versa.
```

Beispiel QuickSortTask


```
public class QuickSortTask implements Runnable {

     static ExecutorService threadPool;
     static ConcurrentLinkedQueue<Future> futureList;

     public void sort(int[] a) {
        int parallelism = java.lang.Runtime.getRuntime().availableProcessors()*2;
        threadPool = Executors.newFixedThreadPool(parallelism);

        futureList = new ConcurrentLinkedQueue<Future>();
        QuickSortTask rootTask = new QuickSortTask(a, 0, a.length - 1);
        futureList.add(threadPool.submit(rootTask));
        while (!futureList.isEmpty()) {
            futureList.poll().get();
        }
        threadPool.shutdown();
     }

     public void run() {
        int l = 0;
        if (left < right) {
            l = partition(a, left, right);
            if (l - left > SPLIT_THRESHOLD) {
                futureList.add(threadPool.submit(new QuickSortTask(a, left, l-1)));
            ...
```

Initialisiere Threadpool

starte ersten Task

warte auf Beendigung aller Tasks

Terminiere Threadpool

füge neuen Task in Threadpool

Fork Join

Fork/Join

School of Engineering

- Neues Framework für die parallele Ausführung ab Java 7
- Macht grundsätzlich dasselbe wie Threadpools
- Threads manchmal immer noch zu schwergewichtig
- "Teile und Herrsche" Prinzip auf Parallelität angewandt

```
Result solve(Problem problem) {
  if (problem is small)
    directly solve problem
  else {
    split problem into independent parts
    fork new subtasks to solve each part
    join all subtasks
    compose result from subresults
  }
}
```

So wird es gemacht

School of Engineering

- Erzeuge ein ForkJoinPool “thread-manager” Object
- Definiere ein Task Object das von RecursiveTask erbt
  - Kann generisch sein, wenn Rückgabewerte vorhanden sind.
  - Instanziere den FJ Pool
  - Instanziere (Haupt-)Task Objekt und rufe `fjpool.invoke(task)` auf

- In der compute Methode
  - Code mit der Aufteilung des Problems
  - Löse Problem direkt falls klein/einfach genug
  - Sonst teile Problem auf:
    - *rufe `invokeAll`(task1, task2, …). dieses wartet bis alle beendet*

  oder

    - *starte task `fork()` auf dem ersten und `invoke`() mit dem zweiten mit anschliessendem `join`()*

Threads vs. Fork/Join

School of Engineering

Threads	Fork/Join
Do subclass **Thread**	Do subclass **RecursiveTask<V>**
Do override **run**	Do override **compute**
Do call **start**	Do call **invoke, invokeAll, fork**
Do call **join**	Do call **join** which returns answer or Do call **invokeAll** on multiple tasks

Beispiel QuickSortForkJoin - invokeAll

```
public class QuickSortForkJoin extends RecursiveAction {

     public static void sort(int[] a) {
        int parallelism = java.lang.Runtime.getRuntime().availableProcessors()*2;
        forkJoinPool = new ForkJoinPool(parallelism);
        QuickSortForkJoin rootTask = new QuickSortForkJoin(a, 0,a.length - 1);
        forkJoinPool.invoke(rootTask);
     }


     public void compute() {
        int l = 0;

        if (left < right) {
            l = partition(a, left, right);
            ForkJoinTask t1 = null, t2 = null;

            if (l - left  > SPLIT_THRESHOLD && right - l > SPLIT_THRESHOLD) {
                t1 = new QuickSortForkJoin(a, left, l-1);
                t2 = new QuickSortForkJoin(a, l , right);
                invokeAll(t1, t2);
            } else {
                QuickSort.sort(a, left, l-1);
                QuickSort.sort(a, l , right);
            }

        }
     }
```

übergebe Task FJ Queue und warte auf Terminierung

übergebe FJ Queue und warte auf Terminierung

Beispiel QuickSortForkJoin - fork/invoke/join

School of Engineering

```
public class QuickSortForkJoin extends RecursiveAction {

     public static void sort(int[] a) {
        int parallelism = java.lang.Runtime.getRuntime().availableProcessors();
        forkJoinPool = new ForkJoinPool(parallelism);
        QuickSortForkJoin rootTask = new QuickSortForkJoin(a, 0,a.length - 1);
        forkJoinPool.invoke(rootTask);
     }

     public void compute() {
        int l = 0;

        if (left < right) {
            l = partition(a, left, right);
            ForkJoinTask t1 = null;
            if (l - left  > SPLIT_THRESHOLD) {
                t1 = new QuickSortForkJoin(a, left, l-1).fork();
            } else QuickSort.sort(a, left, l-1);
            if (right - l > SPLIT_THRESHOLD) {
                new QuickSortForkJoin(a, l , right).invoke();
            } else QuickSort.sort(a, l , right);
            if (t1 != null) {
                t1.join();
            }
        }
     }
```

übergebe Task FJ Queue und warte auf Terminierung

Lösung Funktional

School of Engineering

Java 8 Streams

```
import java.util.*

public class Main {
     private static Function<Integer, Predicate<Integer>> smallerThan = x -> y -> y < x;
     public static List<Integer> qsort(List<Integer> l){
        if(l.isEmpty()) return new ArrayList<>();
        return Stream.concat(Stream.concat(
            qsort(l.stream().skip(1).filter(smallerThan.apply(l.get(0)))
                .collect(Collectors.toList())).stream(),
            Stream.of(l.get(0))),
            qsort(l.stream().skip(1).filter(smallerThan.apply(l.get(0)).negate())
                .collect(Collectors.toList())).stream()).collect(Collectors.toList());
     }

     public static void main(String[] args) {
        List<Integer> l = Arrays.asList(5,6,7,23,4,5645,6,1223,44453,60182,2836,23993, 1);
        System.out.println(qsort(l));
     }
}
```

Haskell

```
qsort [] = []
qsort (x:xs) = qsort (filter (< x) xs) ++ [x] ++ qsort (filter (>= x) xs)
```

Zusammenfassung

School of Engineering

- Teile und Herrsche Prinzip
- Quick Sort
  - Partitionierung
  - Wahl des Pivots
  - Sequentielle Optimierungen
- Optimierung durch Parallelisierung
  - Naive
  - Threads
  - Threadpools
  - Fork/Join