Zufallssurfer, Pagerank

Modell

- Zufallssurfer startet auf einer beliebigen Seite $s_0 \in \{0..n-1\}$ des www und klickt sich von dort weiter auf andere verlinkte Seiten.
- Bei jedem seiner Klicks wird jeder ausgehende Link mit gleicher Wahrscheinlichkeit angewählt.
- Darüber hinaus gibt es eine Grundwahrscheinlichkeit d, dass mit einer beliebigen Seite neu gestartet wird.
- Gibt es keinen ausgehenden Link, so wird wieder gleichverteilt von einer beliebiger Seite gestartet.

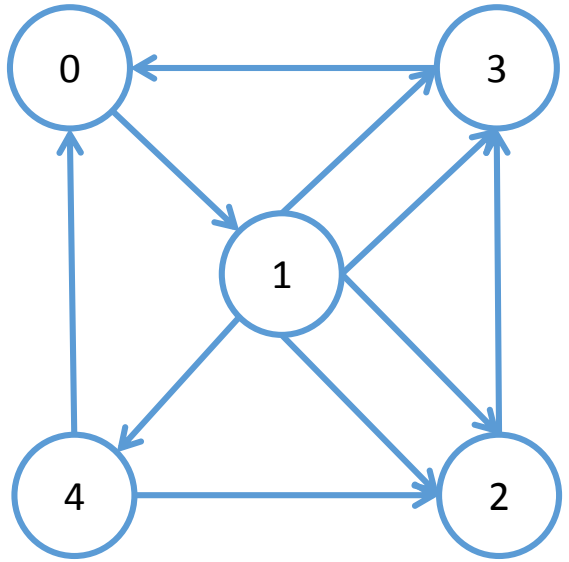

Sedgewick, 1.6.

Fallstudie: Der Zufallssurfer, Pagerank

Frage:

Wie gross ist die Wahrscheinlichkeit, dass er nach sehr langer Zeit auf Seite x landet?

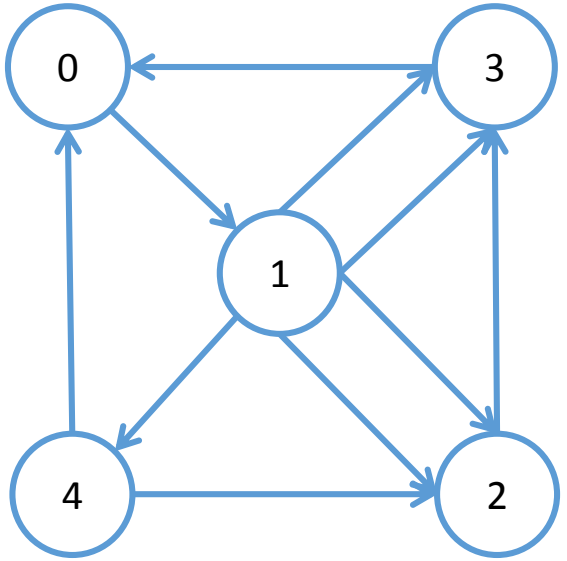

➔ Welche Seite wird langfristig oft angeklickt?

Sedgewick, 1.6.

Die Übergangsmatrix des Random Surfers

Für jede Entscheidung des Zufallssurfers gilt

$$p_{ij} := \mathbb{P}(s_t = j \mid s_{t-1} = i)$$

$$= \begin{cases} d \cdot \frac{1}{n} + (1-d) \cdot \frac{l_{ij}}{c_i} & \text{falls } c_i \neq 0 \\ \frac{1}{n} & \text{sonst} \end{cases}$$

wobei

l_{ij} Anzahl Links von i nach j und

c_i Anzahl ausgehende Links von i

Übergangsmatrix (analog wie beim Ameisenbeispiel):

(p_{ij}) lässt sich als Matrix darstellen und es ergibt sich im vorliegenden Beispiel, mit d=0.1

W't von der Seite 1 startend auf die Seite 4 zu wechseln

$$\boldsymbol{P} := (p_{ij})_{0 \le i,j < n} = \begin{bmatrix} .02 & .92 & .02 & .02 & .02 \\ .02 & .02 & .38 & .38 & .20 \\ .02 & .02 & .02 & .92 & .02 \\ .92 & .02 & .02 & .02 & .02 \\ .47 & .02 & .47 & .02 & .02 \end{bmatrix}$$

Jede Zeile ist ein Wahrscheinlichkeits-vektor

Zwei getrennte Aufgaben

1. Generieren der Übergangsmatrix
   a) Überlegen eines Eingabemodells, Einlesen der Daten
   b) Berechnen der Übergangsmatrix

```
public static double[][] InputLinks(java.util.Scanner scanner)
```

"Separation of Concerns"

2. Simulation
   a) Überlegen wie pro Zeile vorgegangen wird
   b) Simulation durch repetitive Anwendung auf jeweilige Zeile

```
public static double[] Simulate(double[][] p, int iterations)
```

Eingabemodell

Benötigt:

1. Anzahl Seiten
2. Links Quelle → Ziel
3. Terminierung

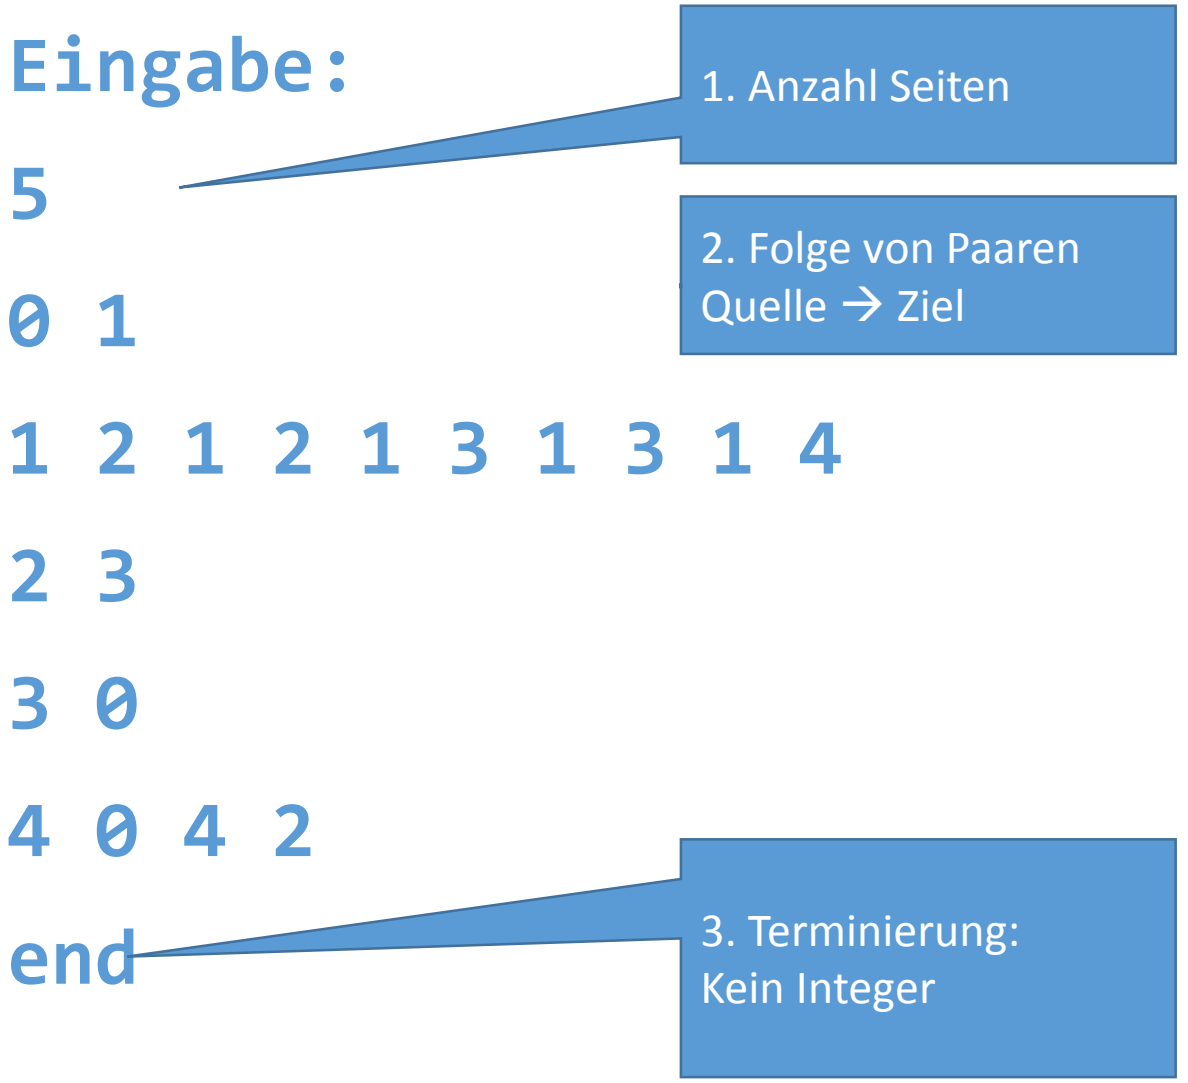

Einlesen der Links

```
public static double[][] InputLinks(java.util.Scanner scanner) {
   int N = scanner.nextInt();           // Anzahl Seiten
   int[][] counts = new int[N][N];      // counts[i][j] = #links Seite i >> j
   int[] outDegree = new int[N];        // outDegree[i] = #links Seite i

   // Akkumulieren der link counts
   while (scanner.hasNextInt()){
      int i = scanner.nextInt();
      int j = scanner.nextInt();
      outDegree[i]++;
      counts[i][j]++;
   }
   ...
```

```
5
0 1
1 2 1 2 1 3 1 3 1 4
2 3
3 0
4 0 4 2
end
```

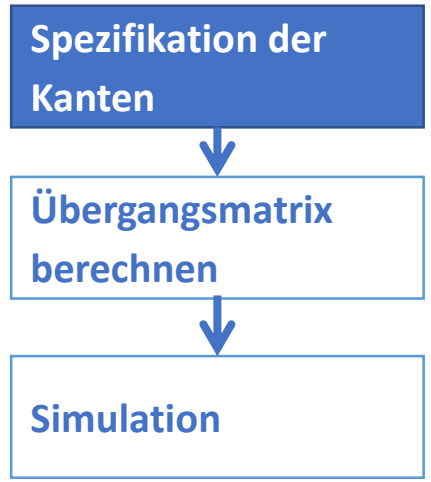

Berechnung der Übergangsmatrix

```
public static double[][] InputLinks(java.util.Scanner scanner) {
   ... // Einlesen: vorige Folie

   double[][] matrix = new double[N][N];
   for (int i = 0; i < N; i++)  {    // W'tsverteilung Zeile i
      for (int j = 0; j < N; j++) {  // W'tswert Spalte j
         if (outDegree[i] > 0)       // Seite i hat ausgehende Kanten
            matrix[i][j] = 0.9*counts[i][j]/outDegree[i] + 0.1/N;
         else                        // Seite i hat keine ausgehende
            matrix[i][j] = 1.0/N;
      }
   }
   return matrix;
}
```

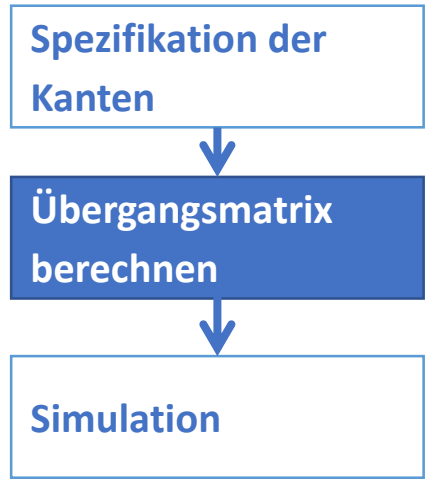

Simulation der Kette

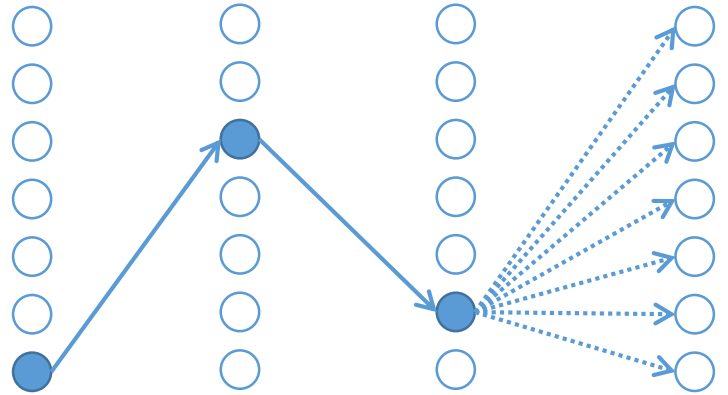

```
public static double[] Simulate(double[][] p, int iterations) {
    int N = p.length;
    double[] freq = new double[N];          // freq[i] = # times surfer hits page i
    int page = 0;                           // start auf Seite 0

    for (int t = 1; t <= iterations; t++){
        page = UnfairDice(p[page]);
        freq[page]++;
    }

    for (int i = 0; i<N; ++i)
        freq[i] /= iterations;
    return freq;
}
```

Eigentliche Kernaufgabe sehr einfach

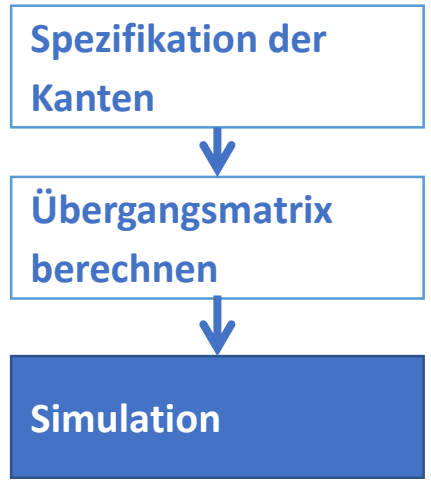

Übrigens: MCMC

Die Simulation, die wir oben ausgeführt haben, ist die Simulation einer **Markov-Kette**

Zufallsbasierte Simulationen nennen wir ja auch Monte-Carlo Verfahren.

Hier haben wir es also sogar mit einem Markov Chain Monte Carlo (**MCMC**) Verfahren zu tun!

MCMC wird vor allem dann verwendet, wenn der Zustandsraum sehr sehr gross ist und man kein anderes Verfahren anwenden kann.

Übrigens: Page Rank

Die Frequenzen, die wir pro Seite berechnen sind ein Mass für die "Beliebtheit" einer Seite und werden als *Pagerank* bezeichnet.

Der Algorithmus von Google zur Auswahl der angezeigten Seiten basiert auf der effizienten Berechnung des Pageranks.

Da das Problem ein Eigenwertproblem ist (siehe Ameisenbeispiel), basiert(e) das Geschäftsmodell von Google auf der Lösung eines Eigenwertproblems für sehr grosse Matrizen.

Klassen und Objekte, Dynamische Speicherallokation, Überladen, Klassen als Datencontainer, Datenkapselung, Klassen, Fallstudie Online Statistik

4. KLASSEN

Klassen und Objekte

An die Stelle von RECORDs in Pascal treten bei Java die *Klassen*

Pascal	Java
RECORDs in Pascal sind reine **Datenobjekte**. Auf ihnen wird mit Prozeduren operiert.	Klassen in Java beherbergen **Daten und Code**. Sie stellen einen Teil des Codes bereit, mit dem auf ihnen operiert wird.
RECORDs sind **wertesemantische** Typen: Instanzen werden automatisch "in place" alloziert.	Klassen in Java haben **Referenzsemantik**: Instanzen müssen mit "new" alloziert werden. Instanzen heissen **Objekte**.

Automatische Speicherallokation: Der Stack

Teil der dynamischen Speicherallokation bereits bekannt: Stack (Aufrufstapel).

- Beim Aufruf von Prozeduren / Funktionen / Methoden wird automatisch Speicher für lokale Variablen und Parameter angelegt, welcher beim Rücksprung wieder freigegeben wird.
- Die Struktur dieses Speichers ist wegen der Unmöglichkeit des *gleichzeitigen* Aufrufs mehrerer Prozeduren besonders einfach: ein Stapel
- Um Verwaltung und Aufbau des Aufrufstapels müssen wir uns glücklicherweise nicht kümmern.

Der Stack: Beispiel

```
static int fac(int n){
      if (n>1)
            return n*fac(n-1);
      else
            return 1;
}
...
System.out.println(fac(4));
```

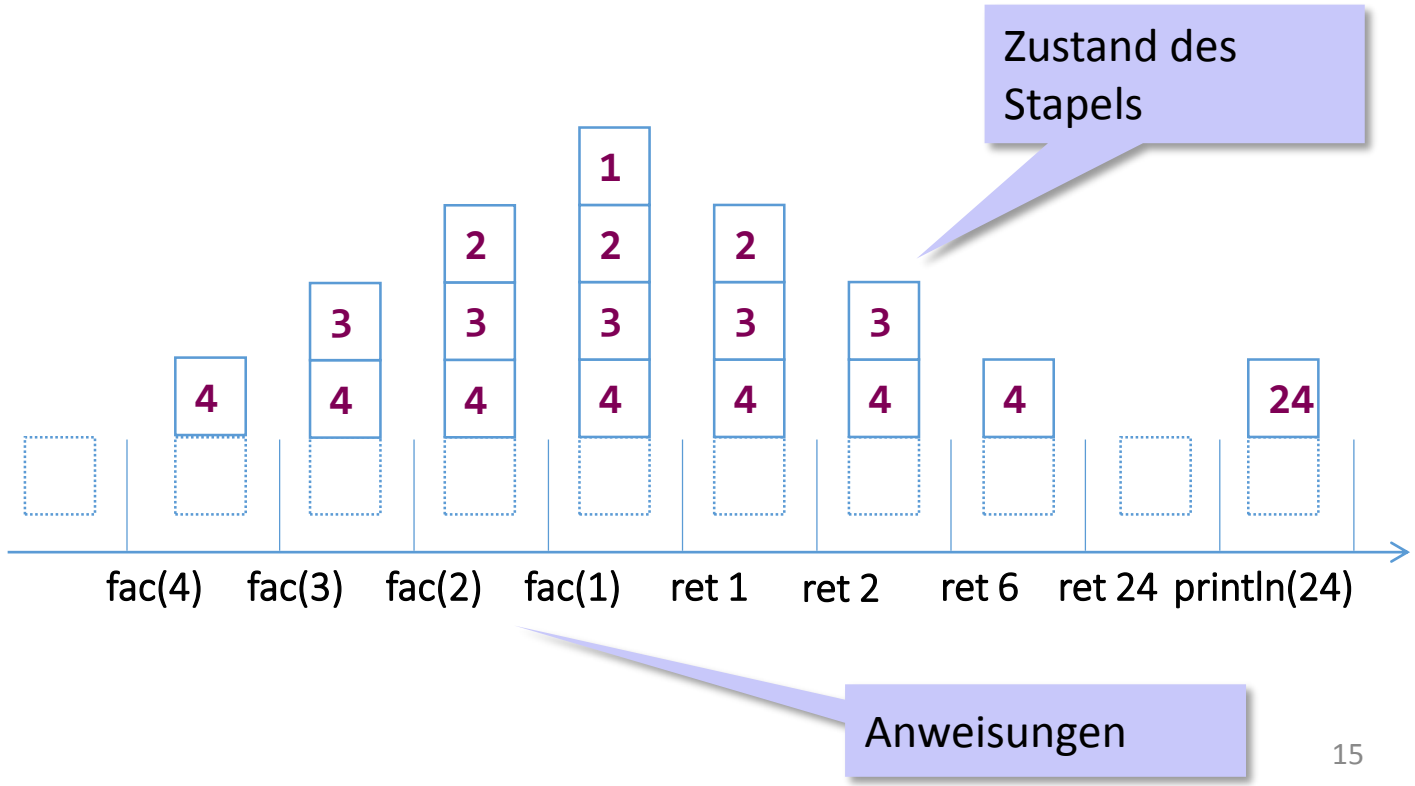

Dynamische Speicherallokation

Für die Implementation von dynamischen Datenstrukturen (später!)

und für die Nutzung von Klassen benötigt man

dynamischen Speicher,

also Speicher den man **explizit** anfordern muss.

Bei Java wird der Speicher, sobald nicht mehr verwendet, von einem *Garbage Collector* abgeräumt.

Allokation mit **new**

Semantik: neuer Speicher für ein Objekt vom Typ *T* wird angelegt

Wert des Ausdrucks ist die Adresse des Objekts

new *T* (par_0, ..., par_n) **Ausdruck vom Typ *T***

(Optionale) Parameter werden dem *Konstruktor* des Typs weitergegeben

```
java.util.Scanner scanner = new java.util.Scanner(System.in);
```

Dynamische Speicherallokation

Mit **new** erzeugte Objekte haben dynamische Speicherdauer. Sie leben, bis sie nicht mehr erreichbar sind.

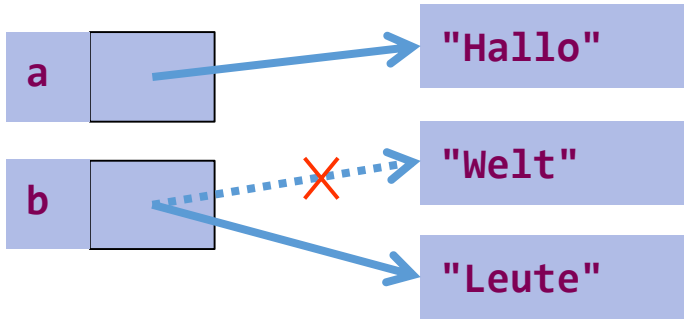


```
String a = new String("Hallo");
String b = new String ("Welt");
System.out.println(a + " " + b); // "Hallo Welt"
b = new String("Leute"); // alter String "Welt" nicht mehr erreichbar
System.out.println(a + " " + b); // "Hallo Leute"
```

Zum Glück müssen wir uns um freigegebene Objekte nicht kümmern. Der Garbage Collector räumt "hinter uns" auf.

Überladen (Overloading)

Methoden sind durch ihren Namen im Gültigkeitsbereich ansprechbar.

Es ist sogar möglich, mehrere Methoden des gleichen Namens zu definieren.

Die richtige Version wird aufgrund der *Signatur* der Funktion ausgewählt.

Overloading

Die ***Signatur*** einer Methode ist bestimmt durch Art, Anzahl und Reihenfolge der Argumente

```
static double sq(double x) { ... }
static int sq(int x) { ... }
static double log(double x, double b) { ... }
static double log(double x) { return log(x,2); }
```

Der Compiler wählt beim Funktionsaufruf automatisch die Funktion, welche "am besten passt"

```
System.out.println(sq(3.3));
System.out.println(sq(3));
System.out.println(log(4,10));
System.out.println(log(3));
```

Overloading

Mit dem Überladen von Funktionen lassen sich also verschiedene Aufrufvarianten des gleichen Algorithmus realisieren

log(d,2), log(d)

und / oder verschiedene Algorithmen für verschiedene Datentypen mit dem gleichen Namen verbinden.

sq(d), sq(i);

Funktioniert ein Algorithmus für verschiedene Datentypen identisch, so verwendet man in Java *Generics.*

Überladen wird auch verwendet bei der Auswahl des geeigneten *Konstruktors* beim Aufruf von **`new`** (kommt gleich!)

Klassen und Objekte: Motivation

Ziel: Netzberechnung für Wasserversorgung

Komponenten: Leitungen, Reservoire, **Pumpen**

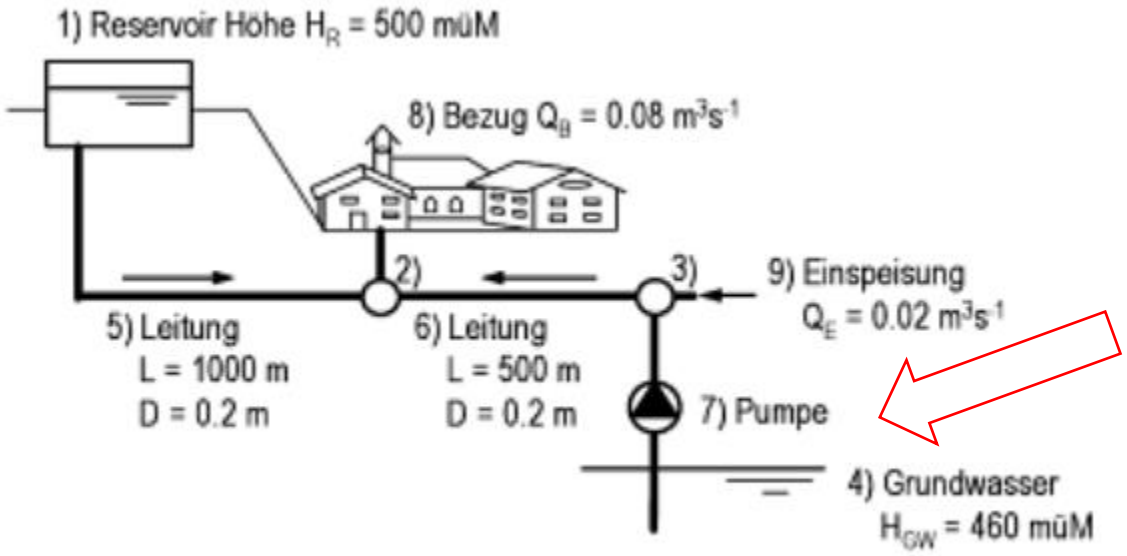

Abb. 11.12. Beispiel zur Netzberechnung: Ein einfaches Wasserversorgungsnetz

Quelle: Siedlungswasserwirtschaft, Willi Gujer, Springer

Klassen als Datencontainer

```
class Pumpe{
  public double h; // manometrische Förderhöhe in m
  public double q; // Fördermenge in m^3/s
}

...
Pumpe p1 = new Pumpe(); // eine Pumpe
p1.h = 40; p1.q = 0.02;

Pumpe p2 = new Pumpe(); // eine andere Pumpe
p2.h = 30; p2.q = 0.01;
```

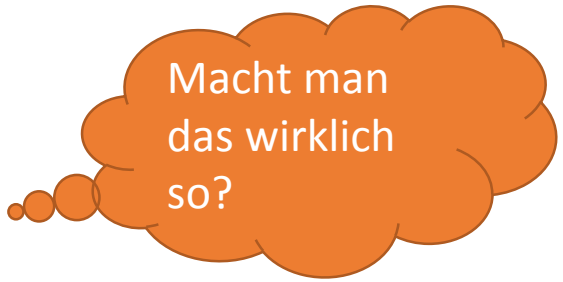

Szenario

Jemand verwendet meine Pumpendaten

soweit ok

```
double v = p1.q * 20; // Fördermenge in 20 Sekunden
```

und verändert die Parameter:

```
p1.h = 50; p1.q = 0.02;
```

oh nein! h = 50 und q = 0.02 liegen doch nicht auf der Kennlinie dieser Pumpe!

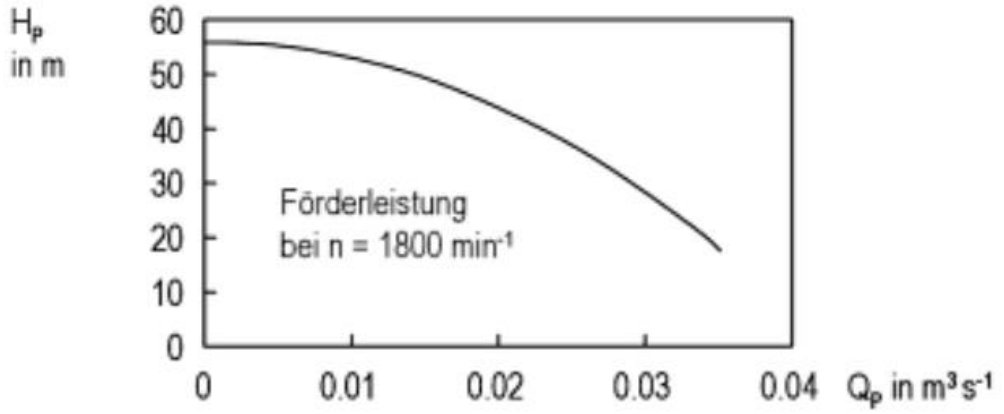

Quelle: Siedlungswasserwirtschaft, Willi Gujer, Springer

➔ **Inkonsistenz!**

Vermeidbar?

Kapseln der Daten!

```
public class Pumpe{
     private double h; // .. in m
     private double q; // .. in m^3/s
}
```

```
Pumpe p1 = new Pumpe();
p1.h = 10; p1.q = 0.02;     // Compilerfehler: kein Schreibzugriff
double v = p1.q * 10;       // Compilerfehler: kein Lesezugriff
```

Konstruktoren

- sind spezielle Methoden, die den Namen der Klasse tragen und keinen Rückgabetyp haben
- können überladen werden, also in der Klasse mehrfach, aber mit verschiedener *Signatur* vorkommen (Überladen!)
- werden beim Aufruf von **`new`** wie eine Funktion aufgerufen. Der Compiler sucht die naheliegendste passende Funktion aus.
- wird kein passender Konstruktor gefunden, so gibt der Compiler eine Fehlermeldung aus.

Konstruktoren

```
public class Pumpe{
   private double h; // .. in m
   private double q; // .. in m^3/s
   // Konstruktor
   public Pumpe (double H, double Q){
      h = H; // Zugriff auf h in diesem Objekt
      q = Q; // Zugriff auf q in diesem Objekt
   }
}

// Initialisiere Pumpe p1 mit h = 40 und q = 0.02
Pumpe p1 = new Pumpe(40, 0.02);  // ok
double v = p1.q * 10;      // Compilerfehler
```

Methoden für Zugriff auf private Daten

```
class Pumpe{
   private double h; // .. in m
   private double q; // .. in m^3/s
   // Konstruktor
   public Pumpe (double H, double Q){
      h = H; q = Q;
   }
   // Getter methoden
   public double GetH(){
      return h;
   }
   public double GetQ(){
      return q;
   }
}
```

Verwendung:

```
Pumpe p1 = new Pumpe (40, 0.02);
Pumpe p2 = new Pumpe(30, 0.01);

// Jeweilige Fördermengen in 1 Stunde
double v1 = p1.GetQ() * 3600;
double v2 = p2.GetQ() * 3600;

// Förderhöhe bei Reihenschaltung
double h = p1.GetH() + p2.GetH();

p1.h = 10; // Compilerfehler. Gut so!
```

Datenkapselung

Eine komplexe Funktionalität wird auf einer möglichst hohen Abstraktionsebene semantisch definiert und durch ein vereinbartes minimales ***Interface*** zugänglich gemacht

Wie der Zustand durch die Datenfelder einer Klasse repräsentiert werden, sollte für den Benutzer nicht sichtbar sein

Dem Benutzer der Klasse wird eine **repräsentations-unabhängige Funktionalität** angeboten

Pumpe mit Kennlinie

```
class Pumpe{
    private double h, q;
    private double[] ha, qa;
    // Konstruktor, wie vorher
    public Pumpe (double H, double Q){
        h = H;
        q = Q;
    }
    // zusätzlicher Konstruktor
    public Pumpe (double[] H, double[] Q){
        ha = H; qa = Q; // Kopien der Referenzen
        h = ha[0]; q = qa[0] // Default Werte
    }
    ...
}
```

Für meine Netzberechnungen
brauche ich
H in Abhängigkeit von Q

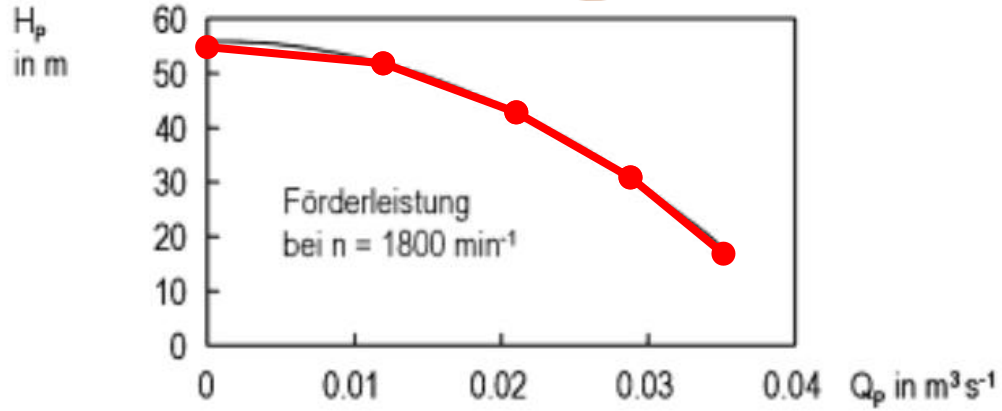


```
double[] h = {55, 50, 40, 30, 20};
double[] q = {0,0.01,0.02,0.03,0.035};
Pumpe p = new Pumpe(h, q)
```

Pumpe mit Kennlinie

Die Pumpe ist immer noch kompatibel zur vorigen Version. Aber sie hat nun noch mehr Funktionalität.

```
class Pumpe{
   public Pumpe (double H, double Q) { ... }
   public Pumpe (double[] H, double[] Q) {...}
   public double GetH() { ... }
   public double GetQ() { ... }
   public static double Interpolate(double x, double[] in, double[] to) {...}

   public double SetH(double H) {
      h = H;
      q = Interpolate(H,ha,qa);
   }
   public double SetQ(double Q) {
      q = Q;
      h = Interpolate(Q,qa,ha);
   }
}
```

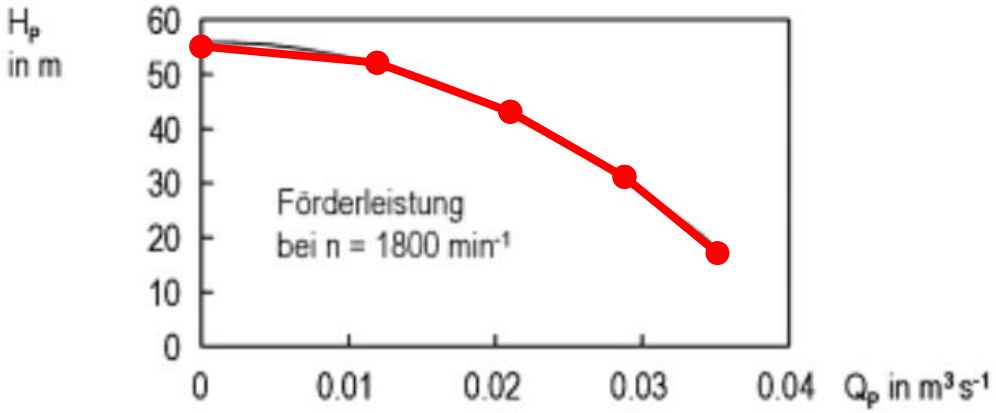

Pumpe mit Kennlinie: Verwendung

```
double[] kennlinieH = {55,50,40,30,20};
double[] kennlinieQ = {0,0.01,0.02,0.03,0.035};
Pumpe p = new Pumpe(kennlinieH, kennlinieQ);
...
p.SetH(45); // Setze Pumpenparameter (Förderhöhe)
...
double v = p.GetQ() * 3600; // Fördermengen in 1 Stunde
```

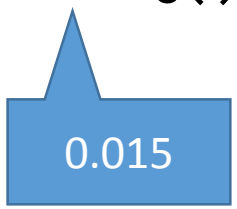

Klassen

Klassen beherbergen das Konzept der Datenkapselung.

Klassen sind Bestandteil nahezu jeder **objektorientierten Programmiersprache.**

Klassen können in Java in Paketen zusammengefasst werden.

Modifizierer für Datenkapselung

```
public class Pumpe{
        private double h;
        private double q;
}
```

Sichtbarkeiten nach Modifizierer

Modifizierer	Klasse	Paket	Sub-Klasse	Global
public	✓	✓	✓	✓
protected	✓	✓	✓	
(keiner)	✓	✓		
private	✓			

Wrapperklassen

Primitive Typen (int, float,..) sind keine Objekte (im OO Sinne)

Java hat Wrapperklassen für jeden primitiven Typ

Manche Methoden der API* fordern Objektreferenzen als Parameter

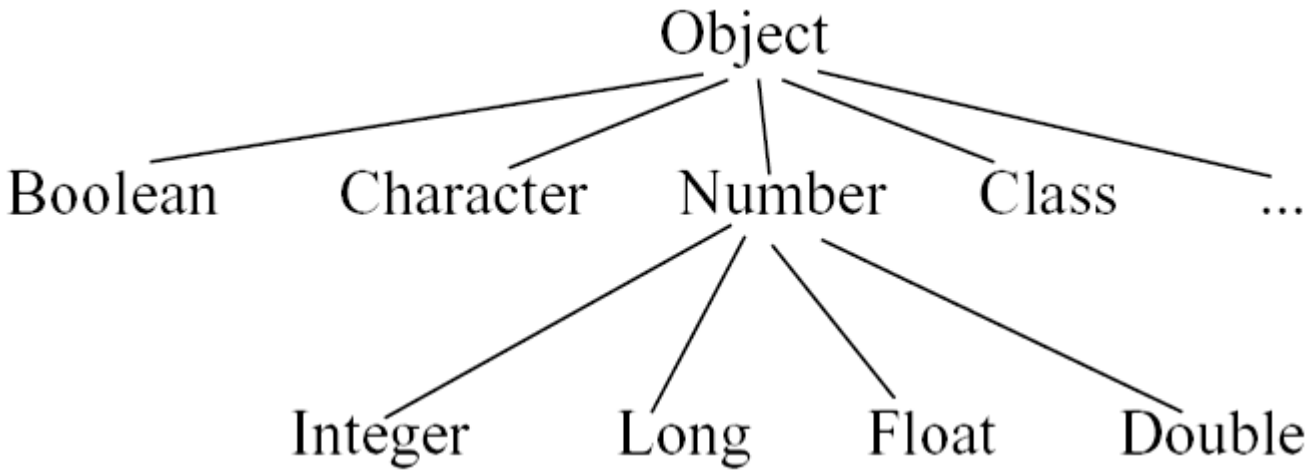

* Application Programming Interface