Suchen in Texten

- Sie wissen wie in einem Text gesucht werden kann
- Sie wissen wie Suchmaschinen arbeiten
- Sie können mit Regex in Java umgehen

Finden eines Teilstrings in einem String

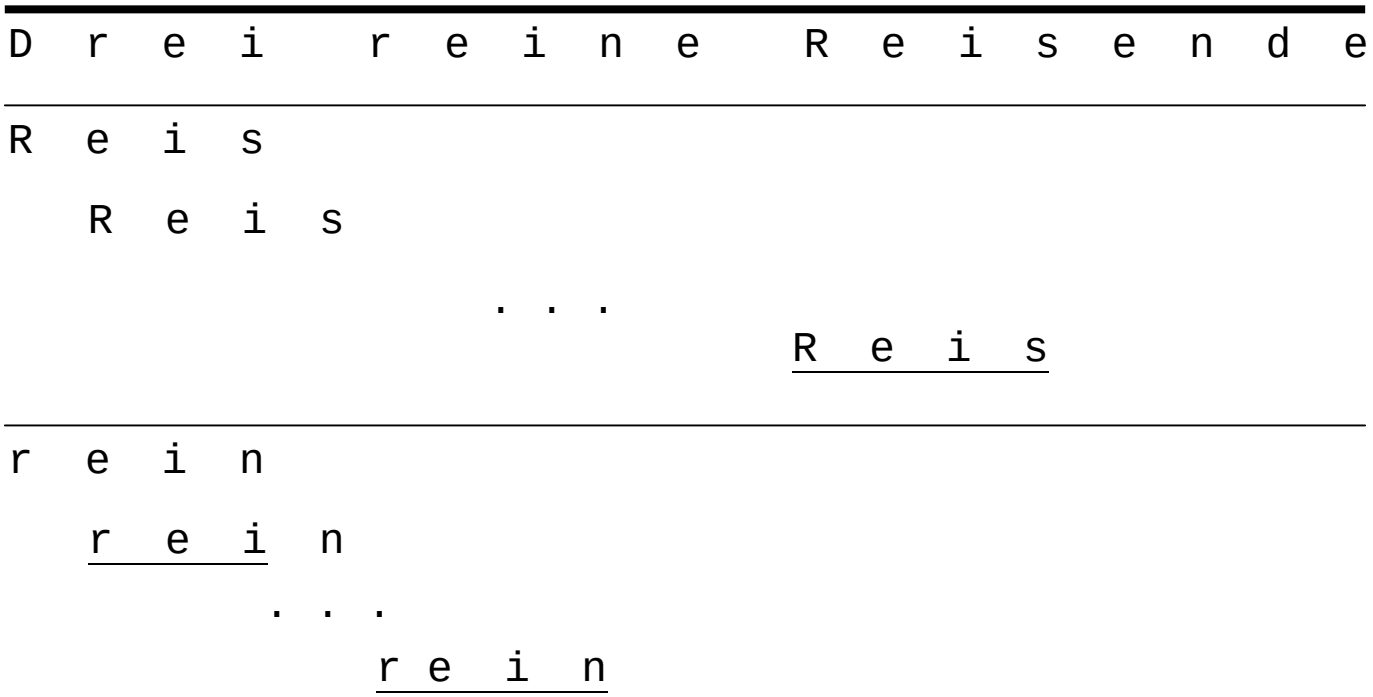

- int indexOf(String str, String pattern)
  - liefert die Position, an der das Muster beginnt
  - -1 falls das Muster nicht vorkommt

Brute-Force Suche in Java

```
static int indexOf(String str, String pattern) {
  for (int i = 0; i < str.length() - pattern.length() + 1; i++) {
    int k;
    for (k = 0;
         k < pattern.length() && str.charAt(i+k) == pattern.charAt(k);
         k++);
    if (k == pattern.length()) return i;
    }
  return -1;
}
```

- Muster wird an die Position i gesetzt
- Es wird mit dem String verglichen bis
  - Ende des Musters erreicht -> Erfolg
  - Nichtübereinstimmung
- Worst-Case Aufwand ist O(n*m)

Beschleunigte Stringsuche: KMP

```
D r e i   r e i n e   R e i s e n d e
---------------------------------------
r e i n

  r e i n
  -----↑
       i+k
    r e i n
    ↑
    i+k
```

- Problem: der String-Zeiger (i+k) wird immer wieder zurück gesetzt
- Idee von KMP: wenn ich bis zum "i" im Suchmuster gekommen bin, dann kann ich direkt weitergehen, wenn im Suchmuster dies das erste Vorkommen ist:
  - im Muster "r e i n" kommt "i" nur einmal vor.
- Aufwand (m + n)
  - aber: Suchmuster muss vorher analysiert (compiliert) werden
  - Suche muss als Automat implementiert werden
- Optimierung von <5% der Fälle (wenn Teilübereinstimmung mit Muster)
- -> theoretisch interessant aber praktisch (heute) irrelevant

Suchmaschinen

Elemente von Suchmaschinen

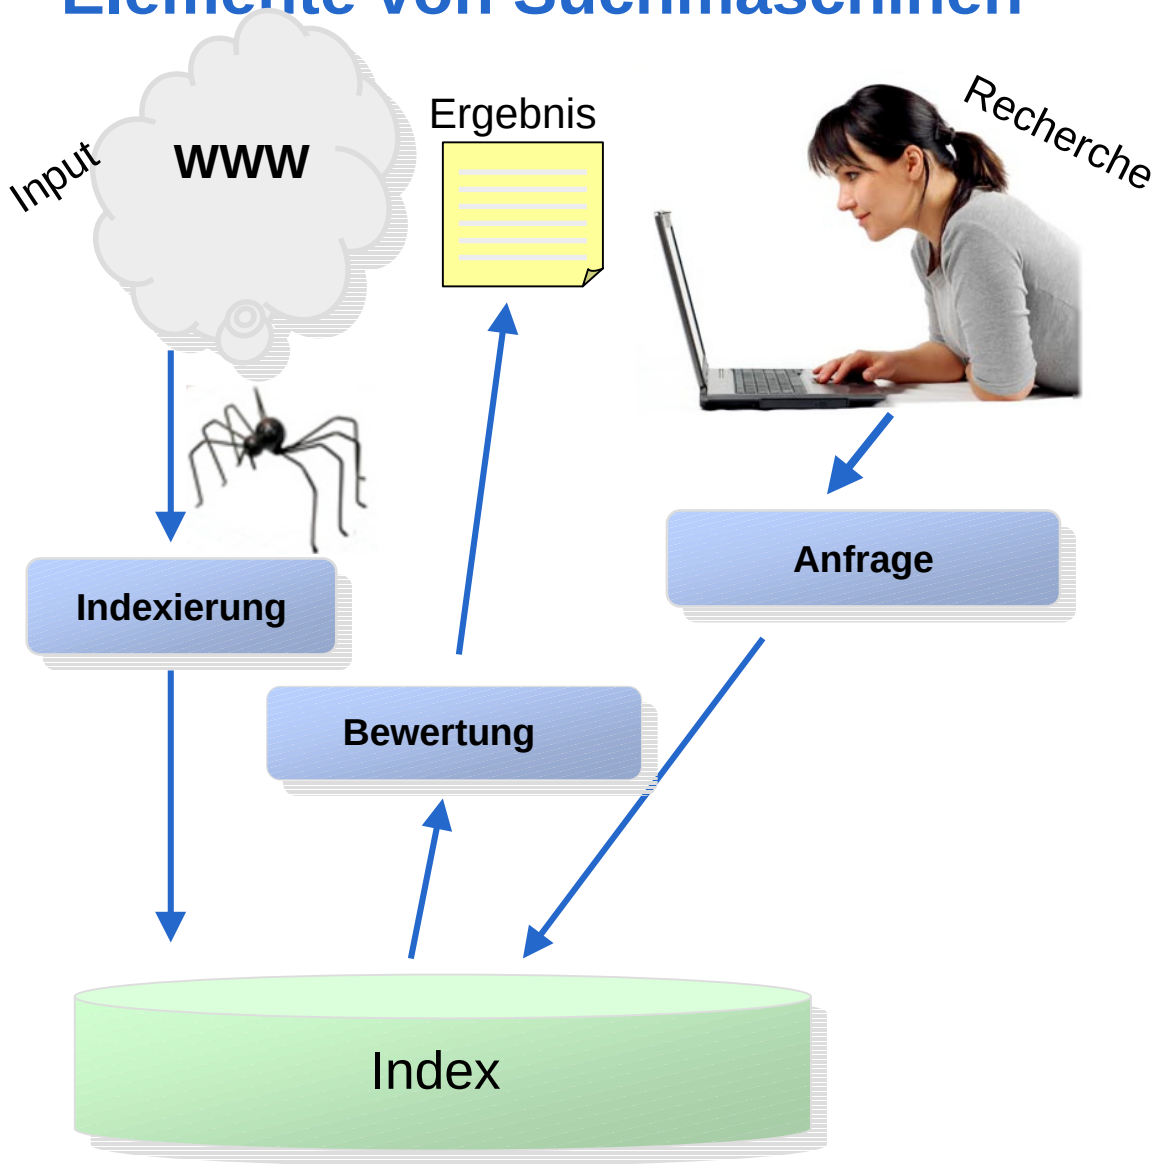

- **Web Roboter/Spider/ Crawler**
  - Durchlaufen regelmässig das Web nach neuen Informationen
- **Indexierung**
  - Aufbereitung von Dokumenten
  - Speicherung im Index / in der Datenbank der Suchmaschine
  - Dateisystem, das für die Suche geeignet ist
- **Retrievalsystem**
  - Suche im Index
  - Sortierung nach Relevanz
    - *Wo kommen die Suchbegriffe vor?*
    - *Wie oft kommen die Begriffe vor?*
    - *In welcher Reihenfolge?*
    - *Wie lang ist der Text?*
    - *Wie viele Links verweisen auf das Dokument?*

Wie funktionieren Suchmaschinen?

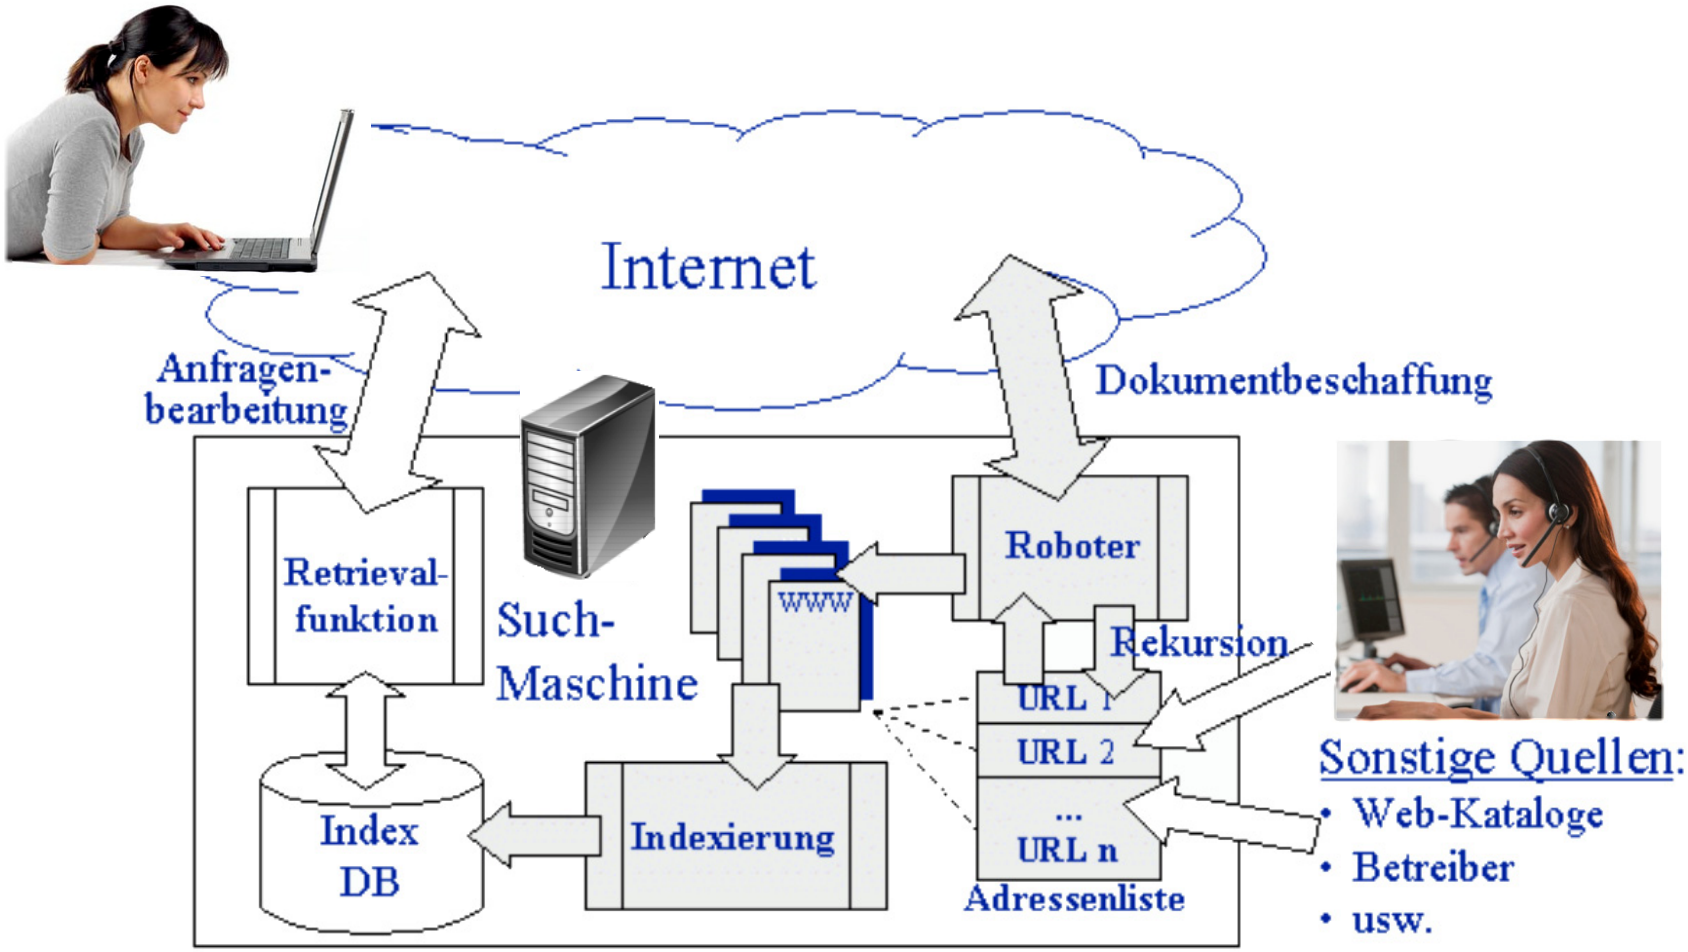

Quelle: Bekavac 2001

Index und Indexierung

- **Index** - Datenstruktur für die unstrukturierten Daten, die so aufgebaut ist, dass sie rasch durchsucht werden kann. (Tabellenform)
- **Indexierung** - Prozess der Erstellung eines Indexes.
- **Bsp**.: Stichwortverzeichnis im Buch
  - Schnellstmögliche Lokalisierung von Seiten, die bestimmte Themen behandeln.
- Google's Index berücksichtigt jeden erreichbaren Text im Internet

Indexierung – invertiertes Dateisystem

- Um einen schnellen Zugriff auf Textdokumente über enthaltene Stichwörter zu ermöglichen, müssen die Texte zu einem invertierten Dateisystem aufbereitet werden. Ein invertiertes Dateisystem besteht aus

- Den **direkten Dateien**. Das sind die Textdokumente.
- Dem **Index**. Das ist eine alphabetische Liste der in den direkten Dateien enthaltenen **Stichwörter**. Jede Indexeintragung verweist wiederum auf eine invertierte Datei.

- Den **invertierten Dateien**. Sie sind die Verbindungen zwischen dem Index und den direkten Dateien. Sie verweisen auf alle Textdokumente, in denen das bestimmte Stichwort vorkommt. Ausserdem enthalten sie Informationen, die für ein Rankingverfahren

Quelle: Glöggler, Kap. 3.2 und 3.3.3

Die direkte Datei

- Verbleiben auf dem Server

Doc1

Er konnte nie über etwas lachen, wie kann ein **Mensch** so tief verflachen!

http://www.morgenstern/texte/text1.html

Doc2

Wozu, so fragt man sich, Reichtum, Wohlstand, Macht, wenn alles dies die Menschen nur verflacht?

http://www.morgenstern/texte/text2.html

Die alphabetische Liste (Ausschnitt)

- **Ein Wort wird nur einmal in den Index aufgenommen**

Wird von Suchmaschine gespeichert

numerisch sortierter Index		alphabetisch sortierter Index	
Wortnr.	Stichwort	Stichwort	Wortnr.
9	ein	konnte	2
10	**mensch**	lachen	6
11	so	macht	20
12	tief	man	16
13	verflachen	**mensch**	10
14	wozu	menschen	25
15	fragt	nie	3
16	man	nur	26
17	sich	reichtum	18
18	reichtum	sich	17

Indexierung – invertiertes Dateisystem

Nr. Stichwort	DocID/url	Position im Text	tag	Frequenz
...	...	...		...
10	http://www.morgenstern/texte/text1.html	10	<b>	1
11	http://www.morgenstern/texte/text1.html http://www.morgenstern/texte/text2.html	11 2	<p> <p>	1 1
...	...	...		...
27	http://www.morgenstern/texte/text2.html	15	<p>	1

Für Bewertung

Levenshtein Distanz

Levenshtein Distanz

- Auch als "Edititierdistanz" bezeichnet
- Wieviele Editieroperationen sind minimal nötig um den einen String in den andern überzuführen
  - **Ersetzen**
  - **Einfügen**
  - **Löschung**

$$
\begin{aligned}
&m = |u| \\
&n = |v| \\
&D_{0,0} = 0 \\
&D_{i,0} = i, 1 \leq i \leq m \\
&D_{0,j} = j, 1 \leq j \leq n \\
&D_{i,j} = \min \begin{cases} D_{i-1,j-1} & +0 \text{ falls } u_i = v_j \\ D_{i-1,j-1} & +1 \text{ (Ersetzung)} \\ D_{i,j-1} & +1 \text{ (Einfügung)} \\ D_{i-1,j} & +1 \text{ (Löschung)} \end{cases} \\
&\quad 1 \leq i \leq m, 1 \leq j \leq n
\end{aligned}
$$

© Wikipedia

Beispiel

"Michael Jackson" **to** "Mendelssohn"

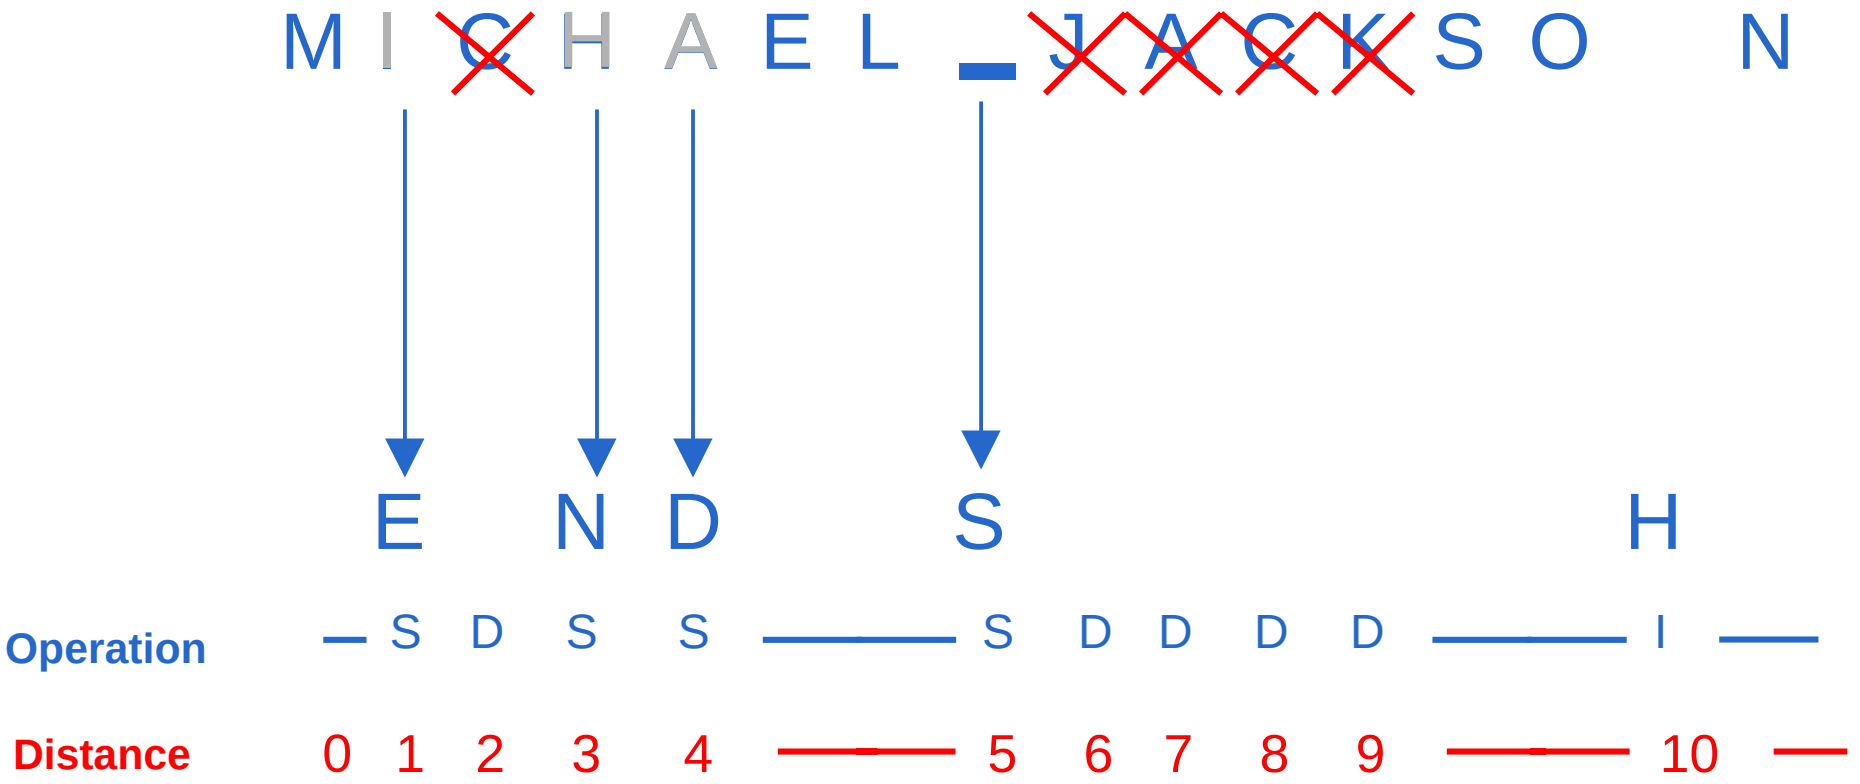

© Intro. to Programming, B. Meyer

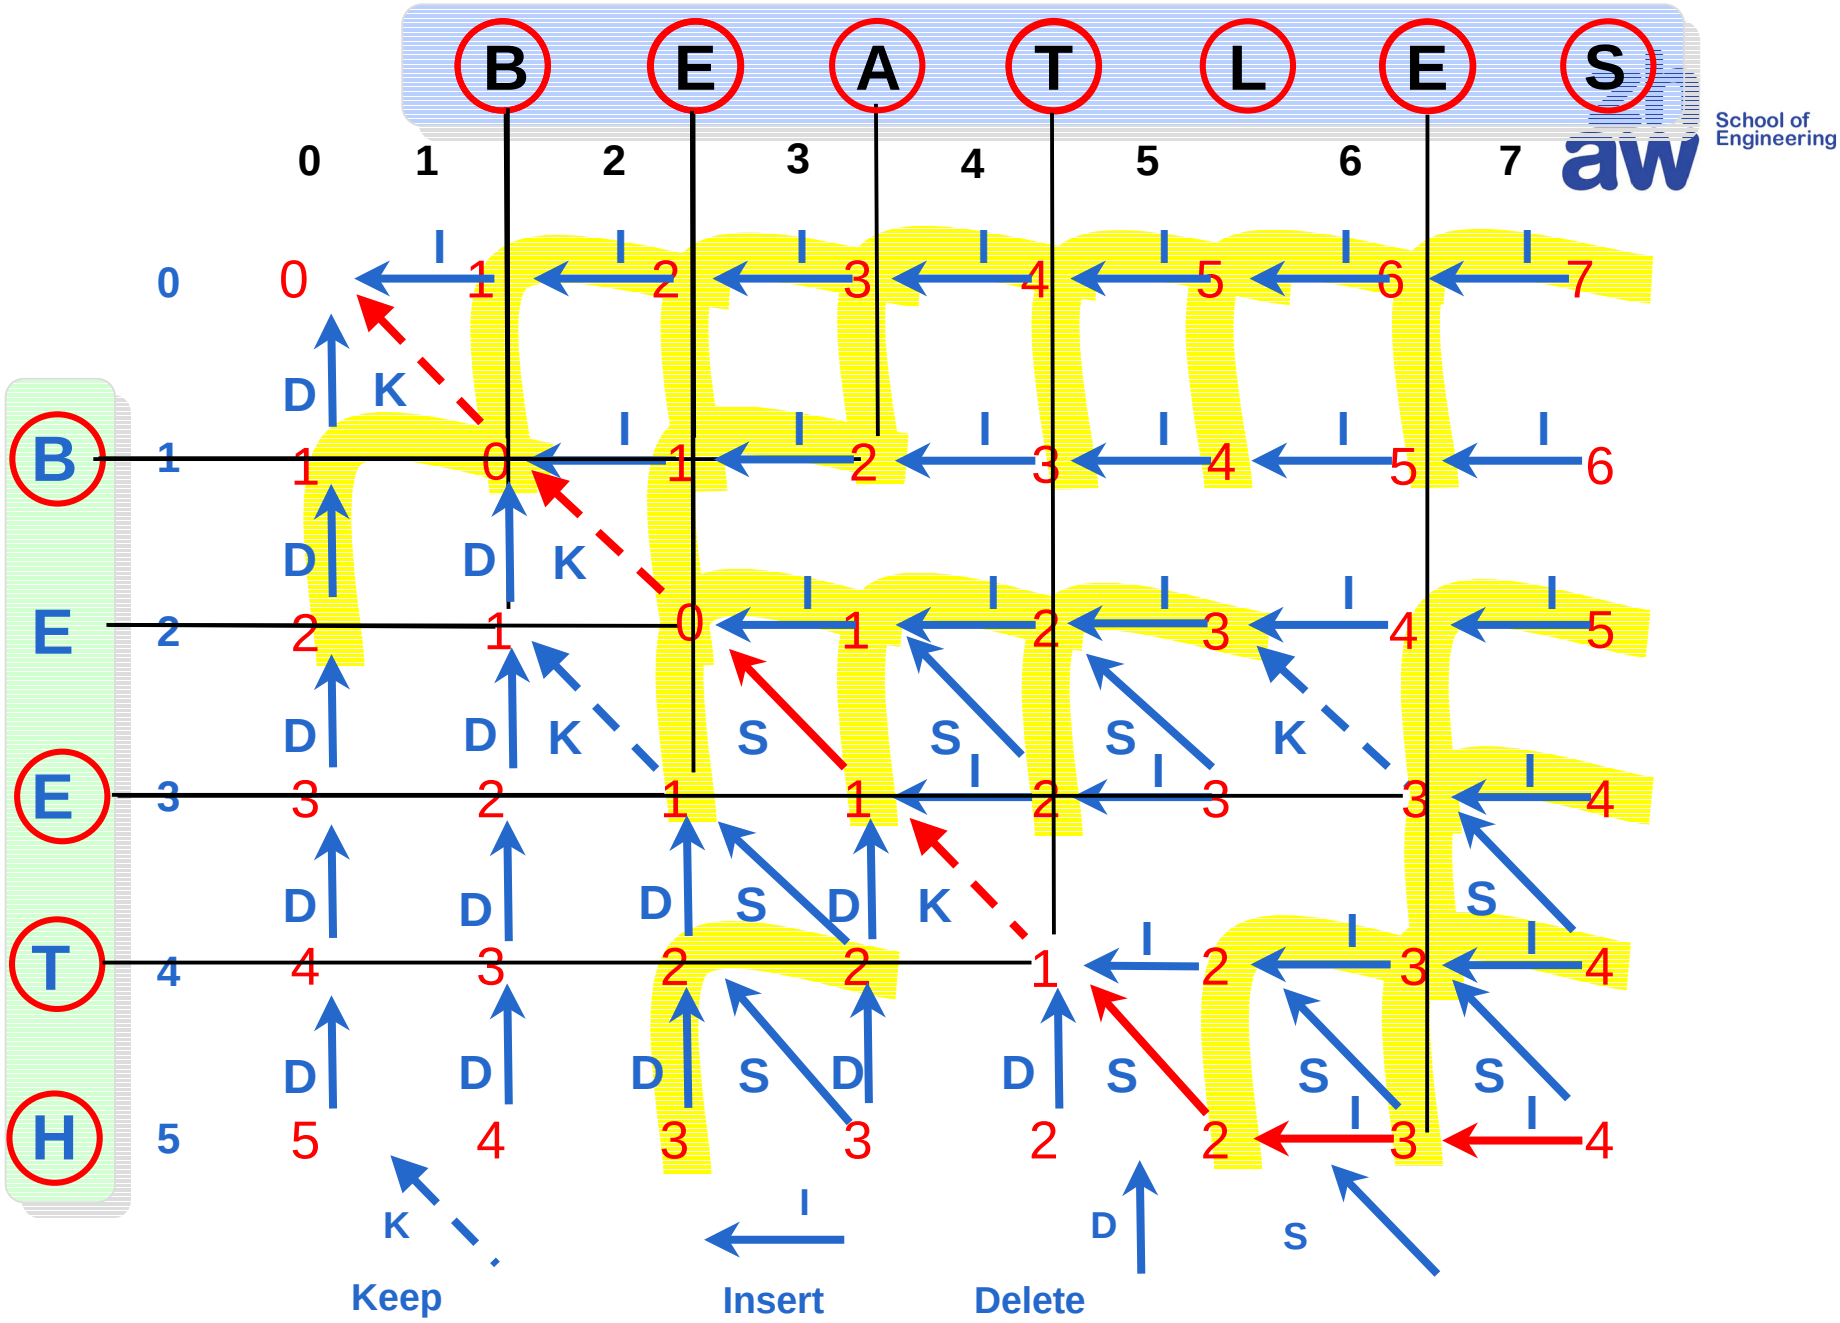
B E A T L E S
0 1 2 3 4 5 6 7
B
E
E
T
H
Keep
Insert
Delete
Substitute

Java Implementation

- Ein 2-dim Array "distance" um die minimale Distanz zwischenzuspeichern

```
public class LevenshteinDistance {
    private static int minimum(int a, int b, int c) {
      return Math.min(Math.min(a, b), c);
    }

    public static int computeLevenshteinDistance(String str1,String str2) {
      int[][] distance = new int[str1.length() + 1][str2.length() + 1];

      for (int i = 0; i <= str1.length(); i++) distance[i][0] = i;
      for (int j = 1; j <= str2.length(); j++) distance[0][j] = j;

      for (int i = 1; i <= str1.length(); i++)
         for (int j = 1; j <= str2.length(); j++) {
            int minEd = (str1.charAt(i - 1) == str2.charAt(j - 1)) ? 0 : 1;
            distance[i][j] = minimum(
                   distance[i - 1][j] + 1,
                   distance[i][j - 1] + 1,
                   distance[i - 1][j - 1]+ minEd);
         }
      return distance[str1.length()][str2.length()];
    }
}
```

Min von 3 Werten

all insert

all delete

equal

substitute

Trigram Suche

Trigram Suche

- Fehlertolerante Suche (auch für Wortverdreher, z.B Vor- Nachname)
- Effizient für grosse Datenbestände
- Index -> Wort in 3-Buchstaben Gruppen unterteilt ,
  - z.B. sind das bei „Peter“, die 3-er Gruppen „PET“, “ETE“, “TER“.
  - Diese 3-er Gruppen werden für alle vorkommenden Worte gebildet und in Hashtabelle gespeichert
- Das zu suchende Wort wird ebenfalls in 3-er Gruppen zerlegt
  - das gesuchte Wort mit am meisten Übereinstimmungen wird genommen

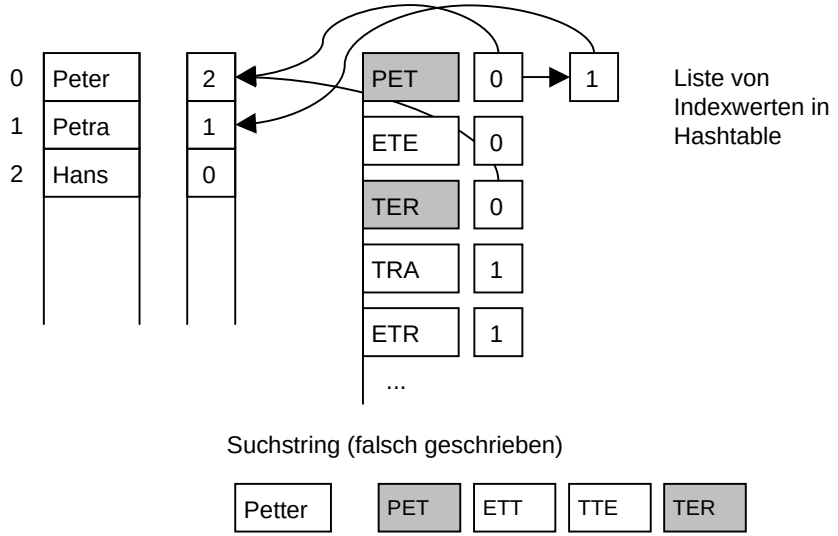

Phonetische Suche

Phonetische Suche

- z.B. Soundex Phrasen nach ihrem Klang in englischer/deutscher Sprache.
- Wort besteht aus seinem ersten Buchstaben, gefolgt von drei Ziffern
  - Kurze Worte: mit 0 auffüllen; 0-werden ignoriert
  - Die Vokale A, E, I, O und U und die Konsonanten H, W und Y sind ausser beim ersten Zeichen zu ignorieren (in D auch ä,ö,ü).
  - Ziffern sind Konsonanten nach folgender Tabelle

E

Ziffer	Repräsentierte Buchstaben
1	B, F, P, V
2	C, G, J, K, Q, S, X, Z
3	D, T
4	L
5	M, N
6	R

D

Ziffer	Repräsentierte Buchstaben
0	a, e, i, o, u, ä, ö, ü, y, j, H
1	b, p, f, v, w
2	c, g, k, q, x, s, z, ß
3	d, t
4	l
5	m, n
6	r
7	ch

- Beispiele

Britney → BRTN → **B635**	bewährten → BRTN → **B635**
Spears → SPRS → **S162**	Superzicke → SPRZCK → S16222 → **S162**

Suchen nach Mustern

Reguläre Ausdrücke: Regex

- Zum Suchen von **definierten Mustern** in Texten d.h. Strings
  - ein bestimmter String: "ZHAW"
  - Muster kann "unscharf" definiert sein: z.B. IT13a, IT12a, IT12c
  - (Teil-)Muster kann sich wiederholen: 170.12.34.12
- Die meisten heutigen Programmiersprachen unterstützen die Suche nach Muster in Form von reguläre Ausdrücke (Regular Expressions oder kurz Regex)
- Regex ist unabhängig von Java definiert
- Java Klassenbibliothek definiert im Package java.util.regex
- die Klassen **Pattern** und **Matcher**

Definition des regulären Ausdrucks

- Zuerst muss der reguläre Ausdruck vorbereitet werden
- Die Klasse **Pattern**
  - `Pattern pat = Pattern.compile("ZHAW");`
- Das Muster kann im einfachsten Fall ein Textzeichen-String sein
- Alle Zeichen sind erlaubt ausser: `([{\^-$|]})?*+.`
- Diese müssen mit \ vorangestellt geschrieben werden
  - Vorsicht in Java String Konstante muss "\\" für "\" geschrieben werden
- Beispiel
  - `Pattern pat = Pattern.compile("wie geht's \\?");`

Abfrage nach den gefundenen Stellen

School of Engineering

- Ausgabe der gefundenen Stellen
- Die Klasse **`Matcher`**
  - `Matcher matcher = pat.matcher("Willkommen an der ZHAW");`
- Suche nächste Textstelle **`boolean find()`**
  - true falls gefunden
  - `matcher.find();`
- Gebe gefunden Teilstring zurück **`String group()`**
  - `matcher.group(); // ZHAW`
- gefundene Start und Endposition innerhalb String **`int start()`** und **`int end()`**
  - `matcher.start(); //18`
  - `matcher.end();  //22`

Vollständiges Beispiel

```
import java.util.regex.*;


…
Pattern pat = Pattern.compile("ZHAW");
Matcher matcher = pat.matcher("Willkommen an der ZHAW");
while (matcher.find()) {
   String group = matcher.group();
   int start = matcher.start();
   int end = matcher.end();
   // do something
}
```

Platzhalter

- Oftmals wird nach unscharfen Muster gesucht, z.B. alle IT Klassen
- Es sind Platzhalter Zeichen erlaubt, die *Zeichenmengen* matchen
  - z.B. "." für beliebiges Zeichen "\d" für Zahl, ^\d für *keine* Zahl

Platzhalter	Beispiel	Bedeutung	Menge der gültigen Literale
`.`	`a.b`	Ein beliebiges Zeichen	aab, acb, aZb, a[b, ...
`\d`	`\d\d`	Digit[0-9]	78, 10
`\D`	`\D`	kein Digit	a, b , c
`^`	`^\d`	Negation	a, b , c
`\s`	`\s`	Leerzeichen (Blank,etc)	blank, tab, cr,
`\S`	`\S`	kein Leerzeichen	

- Aufgabe: Geben Sie das Suchmuster für beliebige IT Klassen an: IT10a, IT08b, IT09c

Eigene Zeichenmengen

- Statt vordefinierte Zeichenmengen zu verwenden, können auch eigene definiert werden
- diese werden in "[" "]" geklammert

- Aufzählung der Zeichen in der Zeichenmenge
  - ein Zeichen aus der Menge
  - z.B. "a", "b" oder "c" : [abc]
- Bereiche
  - z.B. alle Kleinbuchstaben [a-z] alle Buchstaben [a-zA-Z]
- Negation: Alle Zeichen ausser
  - z.B. [^a]
- Aufgabe: Geben Sie das Suchmuster für beliebige IT Klassen an; es gäbe aber nur "a" bis "d"

Optional, Alternative und Wiederholung

- Optionale Teile: ?
  - wenn einzelner Buchstaben optional, z.B. ZHA?W -> ZHW oder ZHAW
- Alternative |
  - wenn ein A oder B -> ZH(A|B)W -> ZHAW oder ZHBW
  - "natürliche" Verwendung von Klammern

Wiederholungen

Auch 0 mal erlaubt

- Beliebig oft *
  - eine Folge von Ziffern \d* -> _, 2,23,323,423,..
- Mindestens einmal +
  - eine Folge von Ziffern aber mindest eine \d+ -> 3,34,234,…
- Bestimmte Anzahl mal {n}
  - eine Folge von drei Ziffern \d{3} -> 341,241,123 ..
- Mindestens, maximal Anzahl mal {n,m}
  - eine Folge von 1 bis 3 Ziffern \d{1,3} -> 1, 23, 124, ...

Zusammenfassung Metasymbole

- (Meta-)Sprache zur Beschreibung der Bildungsregeln von Sätzen
- Metasymbole: `( [ { \ ^ - $ | ] } ) ? * + .`

Metasymbol	Beispiel	Bedeutung	Menge der gültigen Literale
*	ax*b	0 oder mehrere x	ab, axb, axxb, axxxb, ...
+	ax+b	1 oder mehrere x	axb, axxb, axxxb, ...
?	ax?b	x optional	ab, axb
|	a|b	a oder b	a, b
()	x(a|b)x	Gruppierung	xax, xbx
.	a.b	Ein beliebiges Zeichen	aab, acb, aZb, a[b, ...
[]	[abc]x	1 Zeichen aus einer Menge	ax, bx, cx
[-]	[a-h]	Zeichenbereich	a,b,c, ..., h
\d	\d\d	Digit[0-9]	78, 10
\D	\D	kein Digit	a, b , c
^	^\d	Negation	a, b , c
\s	\s	Leerzeichen (Blank,etc)	blank, tab, cr,
\S	\S	kein Leerzeichen	

Übungsbeispiele

Regulärer Ausdruck	Gültigen Sätze
a?b+	
	ein, eine, einer
a(x|y)?b*	
	Binär-Zahlen
	Ganze Zahl

Weitere Methoden für Regex

- **Prüfe ob ganzer String einem Regex Muster entspricht**
- **`boolean matches(String regexp);`**
  - ```
    String text = "Hallo Welt";
    boolean passt;
    passt = text.matches("H.*W.*");
    passt = text.matches("H..o Wel?t");
    passt = text.matches("H[alo]* W[elt]+
    passt = text.matches("Hal+o Welt.+");
    ```

- **Aufgabe: Regex zum Prüfen ob ein String eine Int Zahl enthält**

- **Aufgabe: Regex zum Prüfen ob ein String eine IP Adresse enthält**
    ```

… Weitere Methoden für Regex

- **`String replaceAll(String regexp, String replaceStr);`**
- **`String replaceFirst(String regexp, String replaceStr);`**
  - Ersetzt im gegebenen String alle (bzw. den Ersten bei **`replaceFirst`**) Substrings, die **`regexp`** entsprechen, mit **`replaceStr`**
  - **`String new = text.replaceAll("l+", "LL");  // HaLLo WeLLt`**

- **`String[] split(String regexp);`**
  - Teilt den gegebenen String in mehrere Strings, **`regexp`** ist die Grenzmarke
  - Das Resultat ist ein Array mit Teilstrings
  - **`String data = "4, 5, 6 2,8,, 100, 18"`**
  - **`String[] teile = data.split("[ ,]+");  // Menge der Zeichen " " und","`**
    `// 4 5 6 2 8 100 18`
    `// teile[0] = "4", teile[1] = "5", ….`

Zusammenfassung

- Suche von Strings in Strings
- Suchmaschinen und Index
- Unscharfe Suche
- Suchen nach Mustern

Reguläre Ausdrücke – Lösung

Regulärer Ausdruck	Menge der gültigen Literale
`a?b+`	b, bb, bbb..., ab, abb, abbb...
eine?r?	`{ein, eine, einer}`
`a(x|y)?b*`	a, ax, ay, ab, axb, ayb, abb, axbb...
[_$a-zA-Z][_$a-zA-Z0-9]*	`Java-Bezeichner`
(0|-?[1-9][0-9]*)	`alle ganze Zahlen`