

## Workshop „Datenreinigung“ Duplikaterkennung

8.10.2009  
Felix Naumann

## Überblick

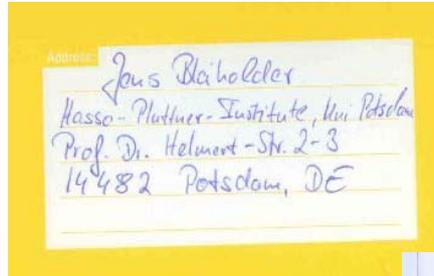
2

- ➔ ■ Das Problem der Duplikaterkennung
- Ähnlichkeitsmaße
  - Edit Distance et al.
- Algorithmen
  - Naiv
  - Blocking
  - Sorted-Neighborhood Methode
    - ◇ Naive, Multipass
    - ◇ Effizient
- Evaluierung

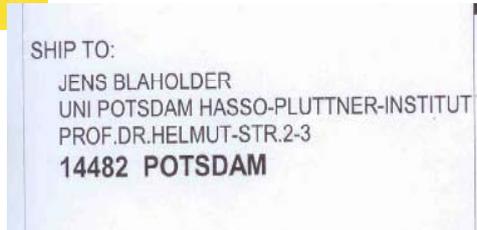


## Wie entstehen Duplikate?

3



Original



Zugestellt

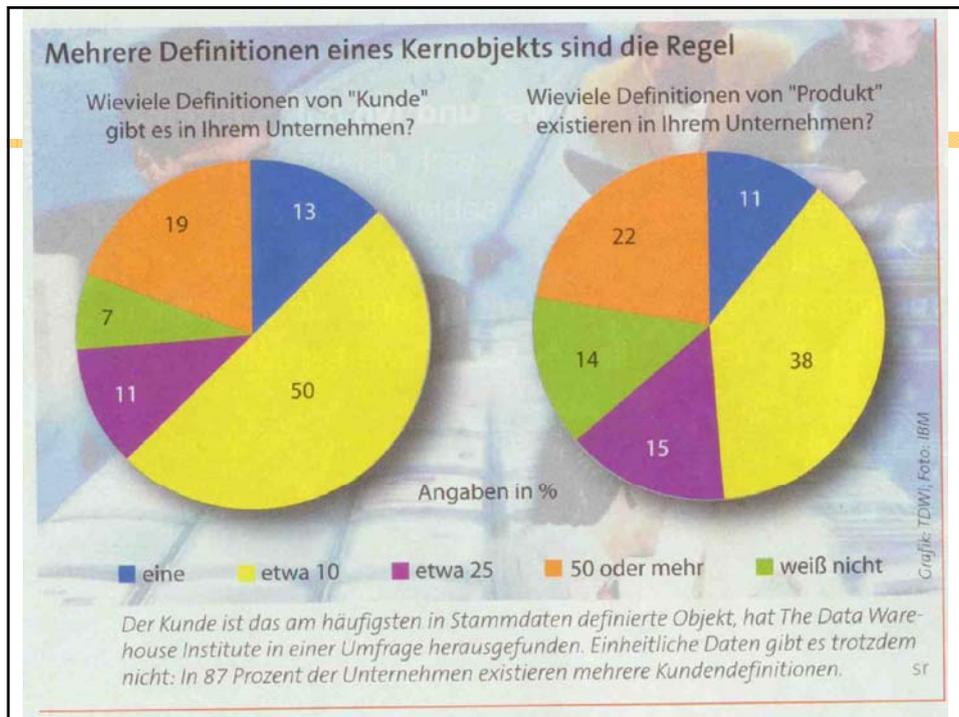
Felix Naumann | Workshop Datenreinigung | Winter 2009

## Wie entstehen Duplikate?

4



Felix Naumann | Workshop Datenreinigung | Winter 2009



## Duplikaterkennung

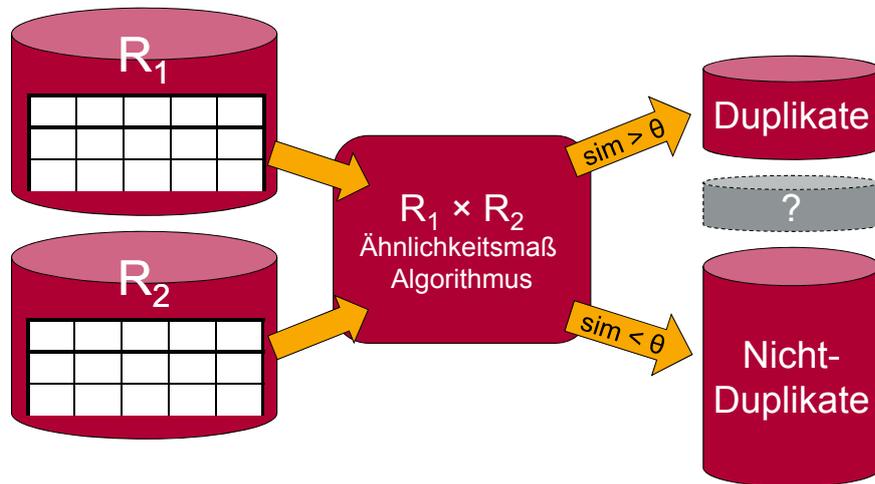
6

Duplikaterkennung ist das Finden mehrerer Repräsentationen desselben Realweltobjekts.

- Problem 1: Repräsentationen sind nicht identisch.
  - *Fuzzy duplicates*
- Lösung: Ähnlichkeitsmaße
  - Wert- und Datensatzvergleiche
  - Domänenunabhängig oder -abhängig
- Problem 2: Die Datenmenge ist groß.
  - Quadratischer Aufwand: Jedes Paar muss verglichen werden.
- Lösung: Algorithmen
  - Z.B. Vergleiche durch Partitionierung vermeiden

## Duplikaterkennung

7



Felix Naumann | Workshop Datenreinigung | Winter 2009

## Wirkungen von Duplikaten

8

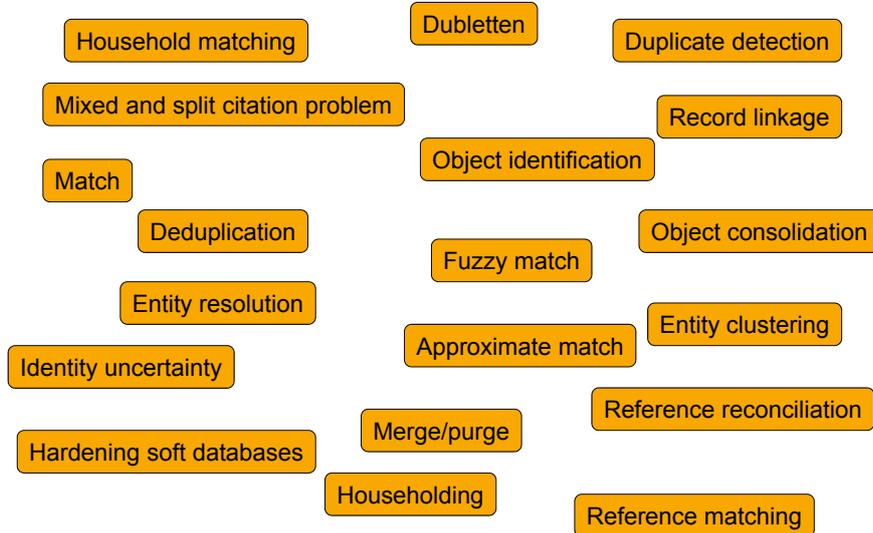
- Mehrfache Zusendung von Katalogen
- Rechnungen werden doppelt bezahlt
- Banken
  - Überschreiten des Kreditlimits wird nicht erkannt
- Lagerhaltung / Einkauf
  - Zu niedriger Lagerbestand einzelner Waren wird ausgewiesen.
  - Kein Ausnutzen von Mengenrabatten bei Bestellungen
- Gesamtumsatz eines Kunden bleibt unbekannt.
- Mehraufwand in der IT
- Sinkende Kundenzufriedenheit
- Potenziale und Gefahren nicht erkannt
- Inkorrekte Kennzahlen

Kunde	Umsatz
BMW	20.000
BaMoWe	5.000.000
Bayerische Motorenwerke	300.000
...	...

Felix Naumann | Workshop Datenreinigung | Winter 2009

# “Duplikaterkennung” hat viele Duplikate

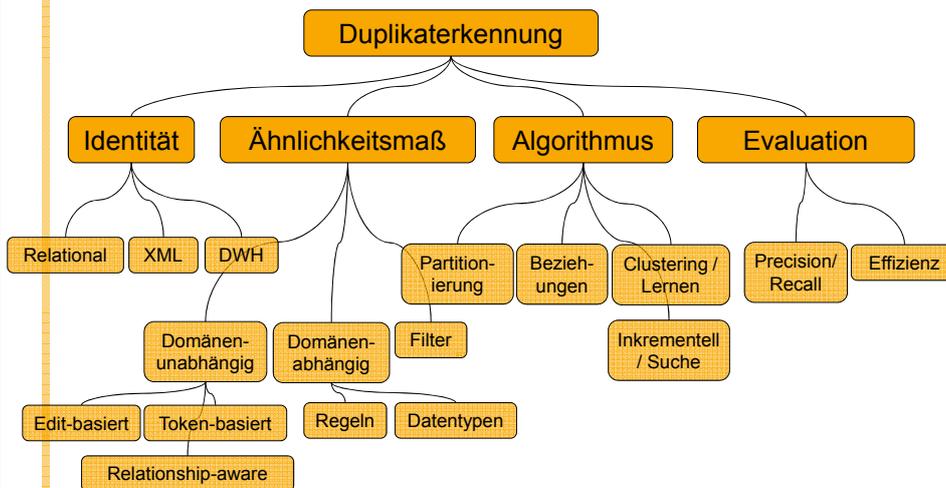
9



Felix Naumann | Workshop Datenreinigung | Winter 2009

# Duplikaterkennung

10



Felix Naumann | Workshop Datenreinigung | Winter 2009

11

- Das Problem der Duplikaterkennung
- Ähnlichkeitsmaße
  - Edit Distance et al.
- Algorithmen
  - Naiv
  - Blocking
  - Sorted-Neighborhood Methode
    - ◇ Naive, Multipass
    - ◇ Effizient
- Evaluierung



12

- Tokens
  - Words / Terms
  - n-grams
- Jaccard
  - $|\{\text{gemeinsame token}\}| / |\{\text{alle token}\}|$
- TFIDF
  - *Term frequency* (tf)
  - *Inverse document frequency* (idf)
  - TFIDF:  $\log(\text{tf}+1) \times \log \text{idf}$
  - Häufige Wörter haben niedriges Gewicht.
  - Ähnlichkeit ist Kosinus der Termvektoren, gewichtet durch TFIDF.
- ...

## Edit-basierte Ähnlichkeitsmaße

13

- Edit-Distanz / Levenshtein-Distanz [Levenshtein 1965]
  - Minimale Anzahl von Edit-Operationen um den einen String in den anderen umzuwandeln.
  - Domänenspezifische Kosten
- Jaro [Jaro 1989] / Jaro-Winkler [Winkler 1999]
  - Common letters within  $\frac{1}{2}$  string length
  - Transposed letters
- Soundex
  - 4-stelliger Code für jedes Wort
  - Verfügbar als Skalar-Funktion in DB2
- ...

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance - Grundlagen

14

Maß zur Ermittlung des „Abstandes“ zweier Zeichenketten

- Literatur: z.B.: [Kuk92]

Abstand := Anzahl an Operationen zur Überführung einer Zeichenkette  $S_1$  in eine Zeichenkette  $S_2$  durch

- Einfügung (**I**nsert)
- Löschung (**D**elete)
- Ersetzung (**R**eplace)
- „Übereinstimmung“ (**M**atch)

Felix Naumann | Workshop Datenreinigung | Winter 2009



## Edit Distance – Beispiel

17

- Beispiel „HASE“  $\Rightarrow$  „RASEN“
  - H  $\rightarrow$  R durch Ersetzung (R)
  - A  $\rightarrow$  A durch Übereinstimmung (M)
  - S  $\rightarrow$  S durch Übereinstimmung (M)
  - E  $\rightarrow$  E durch Übereinstimmung (M)
  - „ “  $\rightarrow$  N durch Einfügung (I)
- Transkript: RMMMI
- EditDistance(HASE,RASEN) = 2
  - Minimal! Woher weiß man das?

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Berechnung

18

### Dynamische Programmierung

- Sei  $D(i,j)$  die edit-distance der Strings  $S_1$  und  $S_2$
- Falls  $|S_1| = m$  und  $|S_2| = n$  ist  $D(m,n)$  die (minimale) edit-distance
- Berechne  $D(m,n)$  durch Berechnung von minimalen Teillösungen für alle Kombinationen  $i \in [0,m]$  und  $j \in [0,n]$
- Prinzip der Optimalität: Bestes (minimales) Transkript zweier Teilstrings ist auch Teil des besten Gesamt-Transkripts.

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Berechnung

19

### Edit-Distance-Matrix (Initialisierung)

		H	A	S	E
	0	1	2	3	4
R	1				
A	2				
S	3				
E	4				
N	5				

$$D(i, 0) = i$$

$$D(0, j) = j$$

$$D(i, j) = \min \{$$

$$D(i-1, j) + 1,$$

$$D(i, j-1) + 1,$$

$$D(i-1, j-1) + d(i, j)$$

$$\}$$

wobei  $d(i, j) = 0$  bei  
Gleichheit,  $d(i, j) = 1$  sonst

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Berechnung

20

### Edit-Distance-Matrix (Berechnung)

		H	A	S	E
	0	1	2	3	4
R	1	1			
A	2				
S	3				
E	4				
N	5				

$$D(i, 0) = i$$

$$D(0, j) = j$$

$$D(i, j) = \min \{$$

$$D(i-1, j) + 1,$$

$$D(i, j-1) + 1,$$

$$D(i-1, j-1) + d(i, j)$$

$$\}$$

wobei  $d(i, j) = 0$  bei  
Gleichheit,  $d(i, j) = 1$  sonst

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Berechnung

21

### Edit-Distance-Matrix (Berechnung)

		H	A	S	E
	0	1	2	3	4
R	1	1	2		
A	2				
S	3				
E	4				
N	5				

$$D(i, 0) = i$$

$$D(0, j) = j$$

$$D(i, j) = \min \{$$

$$D(i-1, j) + 1,$$

$$D(i, j-1) + 1,$$

$$D(i-1, j-1) + d(i, j)$$

$$\}$$

wobei  $d(i, j) = 0$  bei  
Gleichheit,  $d(i, j) = 1$  sonst

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Berechnung

22

### Edit-Distance-Matrix (Ergebnis)

		H	A	S	E
	0	1	2	3	4
R	1	1	2	3	4
A	2	2	1	2	3
S	3	3	2	1	2
E	4	4	3	2	1
N	5	5	4	3	2

Transkript durch Traceback  
rückwärts zum kleinst-  
möglichen Wert nach

- links = DELETE
- oben = INSERT
- diagonal = MATCH  
oder REPLACE

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Edit Distance – Komplexität

23

- Vorteile:
  - Maß für den Unterschied zweier Zeichenketten
  - Ordnung der Treffer möglich, durch Normierung auf  $\max(m,n)$ .
  - Liefert „gute“ Ähnlichkeitswerte für Attributwerte.
  - Einfach erweiterbar (unterschiedliche Gewichtung der Operationen)
- Nachteile:
  - Quadratische Komplexität  $O(m \times n)$ 
    - m: Länge von S1
    - n: Länge von S2
    - Aufbau Matrix:  $m \times n$
    - Traceback:  $m + n$
  - Buchstabendreher werden relativ hoch bewertet.
  - Nicht geeignet für Textdaten oder numerische Werte.

Felix Naumann | Workshop Datenreinigung | Winter 2009

## SOUNDEX

24

- Gleichklingende Wörter werden in einer identischen Zeichenfolge codiert.
  - Soundex („Naumann“) = Soundex („Neuman“) = N550
  - Soundex-Code für ein Wort besteht aus seinem ersten Buchstaben gefolgt von drei Ziffern
  - Ziffern repräsentieren die nach dem Anfangsbuchstaben folgenden Konsonanten
  - Ähnliche Laute besitzen den gleichen Code (B, F, P und V werden z.B. alle mit der Ziffer "1" codiert).
- Soundex wurde von Russell für die Indizierung der Familiennamen der Volkszählung (Census) in den USA entwickelt und 1918 patentiert.

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Spezialisierte Ähnlichkeitsmaße

25

- Stimmen zwei Datumsangaben nicht überein, kann ein Wert für die Ähnlichkeit (zwischen 0 und 1) bestimmt werden:
  - Zerlegen beider Datumsangaben in die Komponenten: Tag, Monat, Jahr
  - Jede Übereinstimmung wird bewertet, z.B. Tag: 0,3; Monat: 0,3; Jahr: 0,4
  - Test, ob einer der häufigen Fehler vorliegt. Geringfügigere Fehler zuerst testen.
  - Liegt einer der häufigen Fehler vor, führt dies zur Aufwertung des Ähnlichkeitswertes, z.B. Vertauschung von Tag und Monat: 0,5
  - Bei immanenter Ähnlichkeit (1. / 1.1. / 1.1.00) ebenfalls Aufwertung, z.B. 0,1
- Beispiel: 6.9.2005 ⇔ 9.6.2005
  - Jahr identisch: 0,4; Tag und Monat vertauscht: 0,5 → Summe = 0,9

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Gesamtähnlichkeitsmaß

26

- Ähnlichkeit pro Attribute ermitteln.
- Dann zusammenführen
  - Durchschnitt
  - Equational theory
- Problem: Was tun mit fehlenden Werten

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Equational theory (Gleichungstheorie)

27

- diktiert die Logik der Domänenäquivalenz oder Kettenäquivalenz.
- benutzt die deklarative regel-basierte Sprache.
- benutzt vordefiniertes Ähnlichkeitsmaß (Abstandsfunktion) mit vordefinierten Grenzwert.
  - Edit distance
  - Phonetic distance
  - Typewriter distance

## Equational theory (Gleichungstheorie)

28

Given two records,  $r_1$  and  $r_2$   
IF last\_name( $r_1$ ) = last\_name( $r_2$ )  
AND edit\_distance(first\_name( $r_1$ ), first\_name( $r_2$ )) < 5,  
AND address( $r_1$ ) = address( $r_2$ )  
THEN  $r_1$  is equivalent to  $r_2$

Given two records,  $r_1$  and  $r_2$   
IF ( ID( $r_1$ ) = ID( $r_2$ ) OR last\_name( $r_1$ ) = last\_name( $r_2$ ) )  
AND address( $r_1$ ) = address( $r_2$ )  
AND city( $r_1$ ) = city( $r_2$ )  
AND (state( $r_1$ ) = state( $r_2$ ) OR zip( $r_1$ ) = zip( $r_2$ ))  
THEN  $r_1$  is equivalent to  $r_2$

## Schwellwerte (threshold)

29

- Schwer zu finden
- Tradeoff zwischen precision und recall
- Viele probieren!
- Idee: Sortieren nach Ähnlichkeit und irgendwo abbrechen

## Überblick

30

- Das Problem der Duplikaterkennung
- Ähnlichkeitsmaße
  - Edit Distance et al.
- Algorithmen
  - Naiv & Blocking
  - Sorted-Neighborhood Methode
    - ◇ Naive, Multipass
    - ◇ Effizient
- Evaluierung



## Record Pairs as Matrix

31

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1																				
2																				
3																				
4																				
5																				
6																				
7																				
8																				
9																				
10																				
11																				
12																				
13																				
14																				
15																				
16																				
17																				
18																				
19																				
20																				

Felix Naumann | OpEN.SC Symposium | May 2009

## Naiver Algorithmus

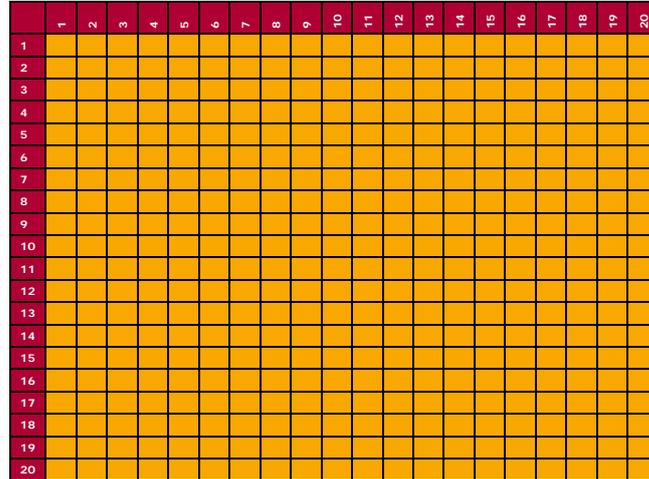
32

- Zwei geschachtelte Schleifen
  - Java
  - SQL
    - ◇ SELECT C1.\*, genID(C1,C2)
    - FROM R as C1, R as C2
    - WHERE sim(C1,C2) > theta
- Aufwand
  - Nur inter-source Duplikate:  $300.000 * 400.000 + 300.000 * 500.000 + 400.000 * 500.000 = 470.000.000.000$
  - Mit intra-source Duplikaten:  $1.200.000^2 = 1.440.000.000.000$
  - Eigentlich:  $(n^2-n)/2$

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Number of comparisons: All pairs

33

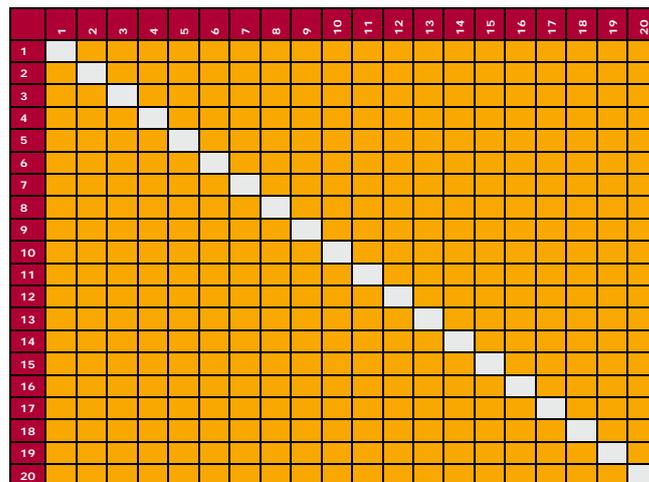


400 comparisons

Felix Naumann | OpEN.SC Symposium | May 2009

## Reflexivity of Similarity

34

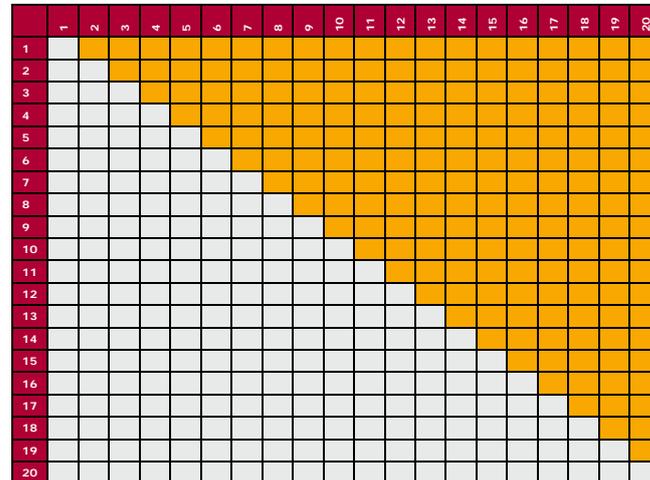


380 comparisons

Felix Naumann | OpEN.SC Symposium | May 2009

## Symmetry of Similarity

35



190 comparisons

Felix Naumann | OpEN.SC Symposium | May 2009

## Complexity

36

Still: Too many comparisons

- 10.000 customers => 49.995.000 comparisons
  - $(n^2 - n) / 2$
  - Each comparison is expensive (complex similarity measures).

Idea: Avoid comparisons by heuristics

- Filtering of records
- Partitionierung



Felix Naumann | OpEN.SC Symposium | May 2009

## Partitioning / Blocking

37

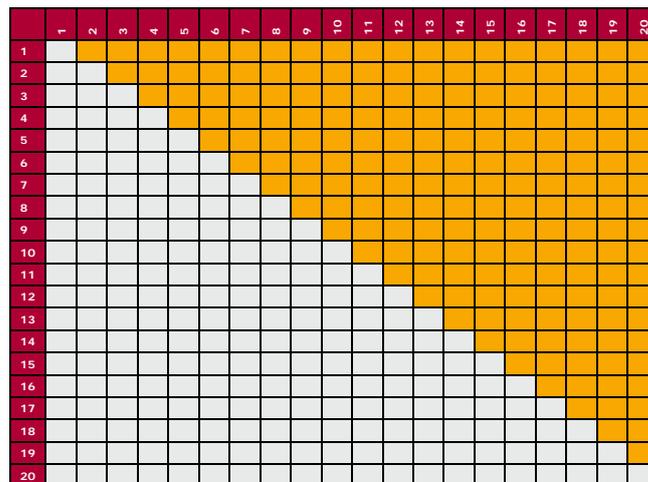
- Partition the records (horizontally) and compare pairs of records only within a partition.
  - Partitioning by first two zip-digits
    - ◇ Ca. 100 partitions in Germany
    - ◇ Ca. 100 customers per partition
    - ◇ => 495.000 comparisons
  - Partition by first letter of surname
  - ...
  
- Idea: Partition multiple times by different criteria.
  - Then apply transitive closure on discovered duplicates.



Source: wikipedia.de

## Records sorted by ZIP

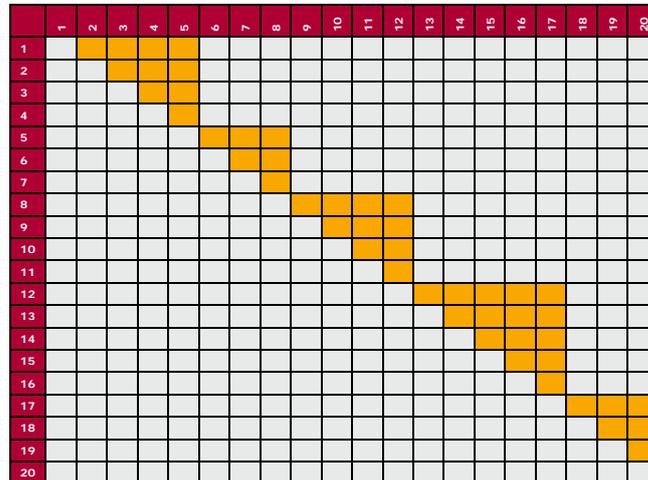
38



190 comparisons

## Blocking by ZIP

39



47  
comparisons

Felix Naumann | OpEN.SC Symposium | May 2009

## Blocking / Gruppierung / Partitionierung

40

- Die Kunst: Geeignete Kriterien finden
  - Gruppieren nach Stadt
  - Gruppieren nach erstem Buchstaben des Nachnamen
  - Gruppieren nach PLZ und Vorname
  - Jede Gruppe sollte in den Hauptspeicher passen
  - Gruppierungskriterium sollten möglichst fehlerfreie Attribute sein
- Praktisch:
  - Sortierung mit SQL (nicht GROUP BY)
- Weiter: Mehrere Durchläufe mit unterschiedlichen Kriterien

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Mehrfache Partitionierung

41

- Probleme
  - Datenfehler in PLZ
  - Umzug
  - => Duplikat nicht erkannt
  
- Idee:
  - Partitioniere mehrfach nach unterschiedlichen Kriterien
    - ◇ PLZ, Nachname, zusammengesetzter Schlüssel
  - Bilde Transitive Hülle
    - ◇ Durchgang 1:  $A = B$
    - ◇ Durchgang 2:  $B = C$
    - ◇ Transitive Hülle:  $A = C$

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Überblick

42

- Das Problem der Duplikaterkennung
- Ähnlichkeitsmaße
  - Edit Distance et al.
- Algorithmen
  - Naiv & Blocking
  - Sorted-Neighborhood Methode
    - ◇ Naive, Multipass
    - ◇ Effizient
- Evaluierung



Felix Naumann | Workshop Datenreinigung | Winter 2009

## Die Sorted Neighborhood Methode

43

- Input:
  - Tabelle mit N Tuplen
  - Ähnlichkeitsmaß (basierend auf Edit distance)
- Output:
  - Klassen (clusters) der äquivalenten Tupel (= Duplikate)
- Problem: Viele Tupel
  - Vergleich eines jeden Tupelpaares zu aufwendig (Effizienz).
  - Tabelle passt nicht in den Speicher (Skalierbarkeit).

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Sorted Neighborhood

44

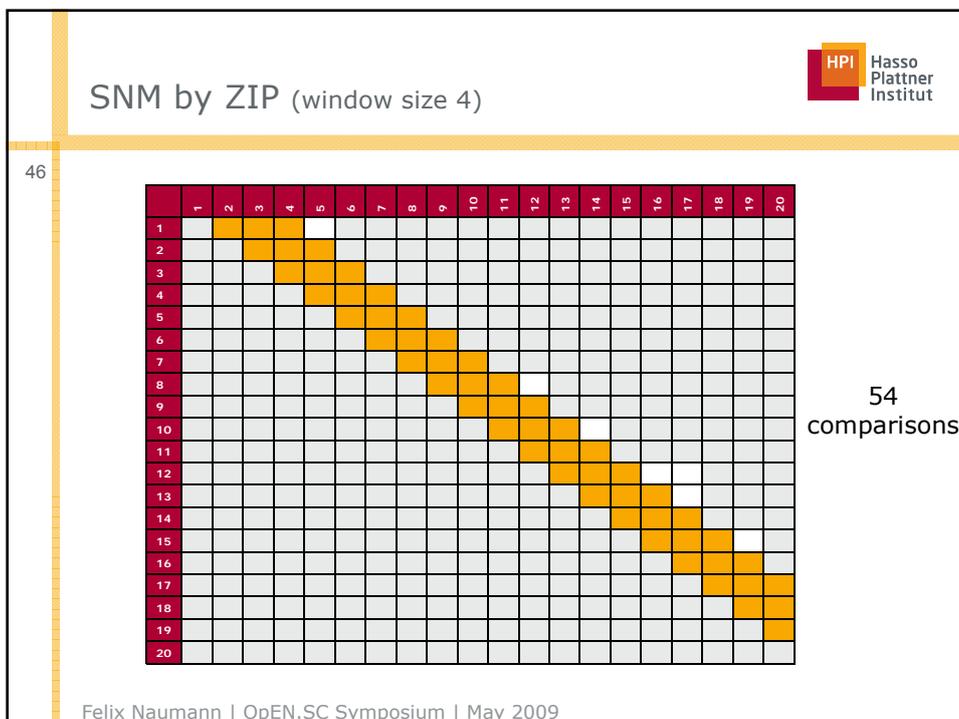
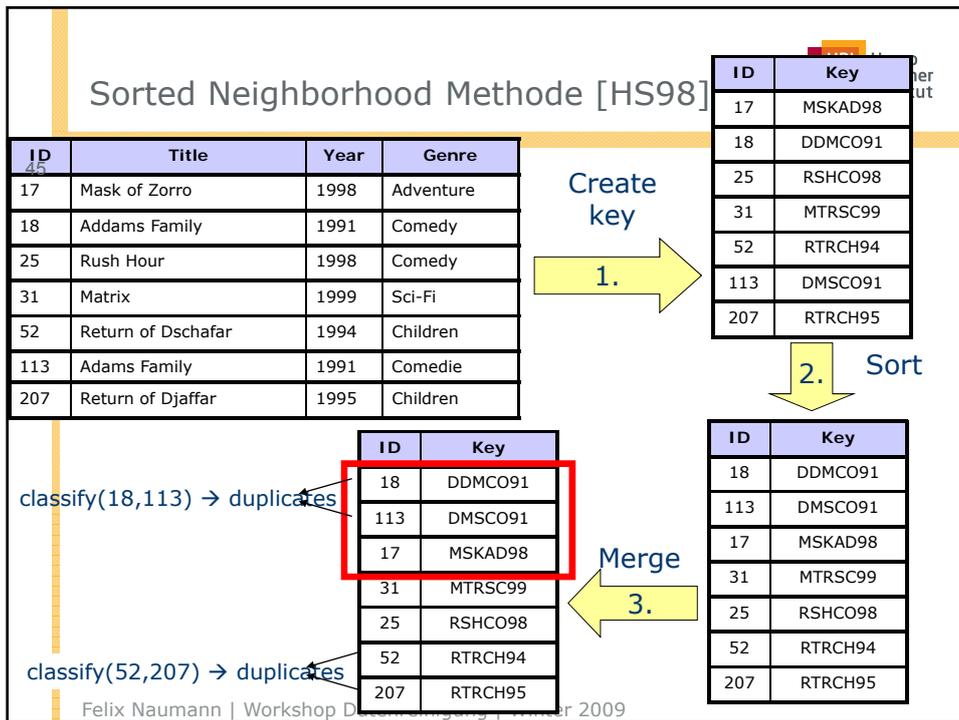
### Idee

- Daten geschickt partitionieren.
- Nur innerhalb dieser Partitionen Duplikate suchen.

### Algorithmus nach [HS98]

1. Create Key:
  - Schlüssel mittels relevanter Feldern erzeugen.
  - ◇ Sequenz einer Teilmenge von Attributen oder der Teilketten innerhalb der Attribute.
  - ◇ Effektivität des Algorithmus ist von Schlüsselauswahl abhängig.
  - ◇ Schlüssel ist nur virtuell und nicht eindeutig.
    - Wird nur für Sortierung benutzt.
2. Sort:
  - Daten nach dem Schlüssel sortieren.
3. Merge:
  - Fenster (der Größe  $w$ ) über sortierte Tupel schieben.
  - Nur Tupel innerhalb des Fensters miteinander vergleichen.

Felix Naumann | Workshop Datenreinigung | Winter 2009



## Sorted Neighborhood – Aufwand

47

### Aufwand

- $N$  : Anzahl der Tupel,  $w$ : Fenstergröße (window)
- Theoretisch:
  - $O(N) + O(N \log N) + O(w N) = O(N \log N)$ 
    - ◇ bei  $w < \log N$ ;  $O(wN)$  sonst
- Praktisch:
  - Drei Läufe über die Daten auf der Festplatte

## Sorted Neighborhood – Aufwand

48

### Kommentare

- Wahl des Schlüssels
  - Formulierung durch Experten
  - Aufwändig
  - Schwer vergleichbare Ergebnisse
  - Für Effektivität entscheidend
- Wahl der Fenstergröße
  - $w = N$  :  $O(N^2) \Rightarrow$  max. accuracy & max. Zeit
  - $w = 2$  :  $O(N) \Rightarrow$  min. accuracy & min. Zeit
- Entscheidung ob ein Duplikat vorliegt, ist eine komplexe Berechnung (edit distance).

## Sorted Neighborhood – Multipass Verfahren

49

- Problematische Schlüsselwahl
  - Beispiel: Schlüssel beginnt mit ID
    - ◇  $r_1$ : 193456782 und  $r_2$ : 913456782
- Problemlösung 1:
  - Vergrößerung des Fensters:  $w \rightarrow N$
- Problemlösung 2:
  - Multipass Verfahren

## Sorted Neighborhood – Multipass Verfahren

50

- Mehrmalige Durchführung von Sorted Neighborhood Methode mit verschiedenen Schlüsseln
- $w$  relativ klein
- Transitive Hülle auf Ergebnissen jedes Durchgangs:
  - $\text{Equivalent}(a, b) \ \&\& \ \text{Equivalent}(b, c)$   
⇒  $\text{Equivalent}(a, c)$
  - Dadurch werde neue Duplikate gefunden.

## Überblick

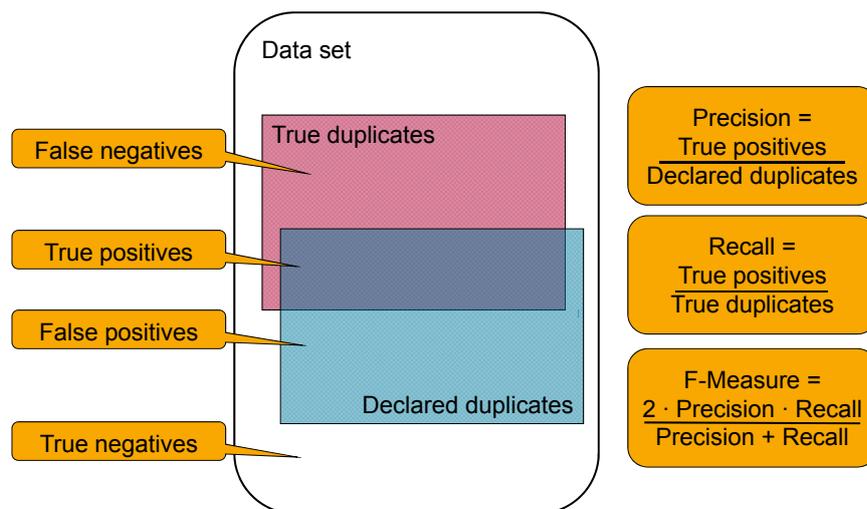
51

- Das Problem der Duplikaterkennung
- Ähnlichkeitsmaße
  - Edit Distance et al.
- Algorithmen
  - Naiv & Blocking
  - Sorted-Neighborhood Methode
    - ◇ Naive, Multipass
    - ◇ Effizient
- Evaluierung

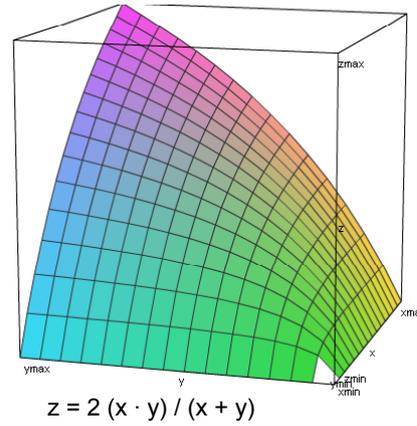
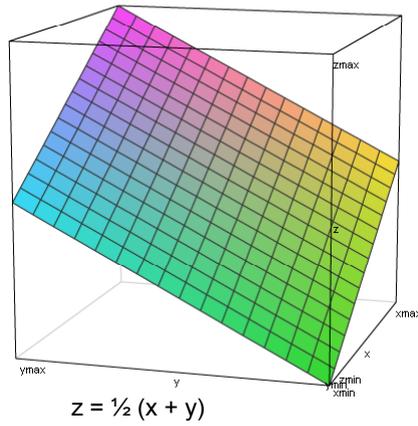


## Precision & Recall

52



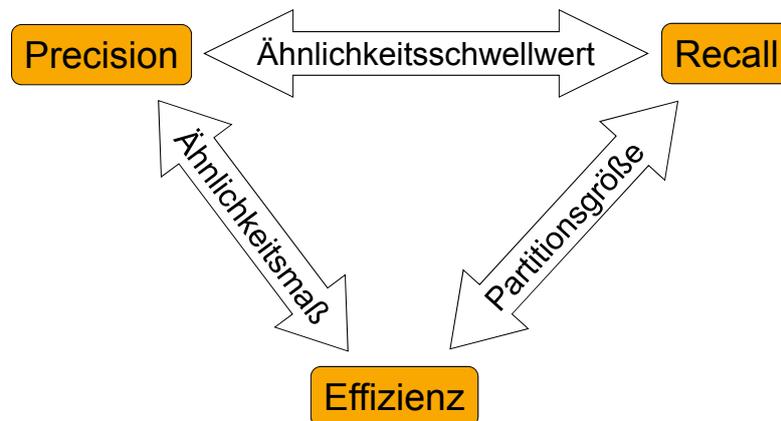
## Arithmetisches Mittel („Durchschnitt“) vs. Harmonisches Mittel („F-Maß“)



53

## Duplikaterkennung – Zielkonflikte

54



## Zusammenfassung des Vorgehens

55

Gegeben zwei Tupelmengen A und B

Kernidee:

- Bilde Kreuzprodukt aller Tupel.
- Für jedes Paar berechne Ähnlichkeit
  - Z.B. bzgl. Attributwerte
  - Z.B. bzgl. Beziehungen zu anderen Tabellen (Fremdschlüssel)
  - usw.
- Wähle Duplikatpaare aus
  - Ähnlichste Paare bis Schwellwert
  - Nebenbedingungen
- Bilde Duplikatcluster
  - Transitive Hülle

Edit Distance

Containment metric

Sorted Neighborhood Methode

Probleme

- Anzahl und Komplexität der Vergleiche (Effizienz)
- Güte des Ähnlichkeitsmaßes (Effektivität)
- Große Datenmengen (Skalierbarkeit)

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Datenfusion

56



0766607194	H. Melville		\$3.98	
------------	-------------	--	--------	--



0766607194	Herman Melville	Moby Dick	\$5.99	
------------	-----------------	-----------	--------	--



Felix Naumann | Workshop Datenreinigung | Winter 2009

## Abgabe bis 18 Uhr

57

- Liste mit IDs der Duplikatpaare
- Kleinere ID eines Paares zuerst
  - Numerisch!
- Sonstige Sortierung ist egal
- Ein Paar pro Zeile
- Trennung der IDs durch Komma
  - 3, 25
  - 5, 11
  - 2, 39
  - 45, 123
  - ...
- Trick 1
  - Leere Liste abgeben
  - Precision = 1
  - Aber Recall schlecht
- Trick 2
  - Alle Paare abgeben
    - ◇ Passt nicht in E-Mail
  - Recall = 1
  - Aber precision schlecht

Felix Naumann | Workshop Datenreinigung | Winter 2009

## Literatur

58

- [RD00] Data Cleaning: Problems and Current Approaches, E. Rahm and H.H. Do, IEEE Bulletin 23(4), 2000.
- [Kuk92] Technique for automatically correcting words in text, ACM Computing Survey 24(4), 1992, Karen Kukich
- [HS98] M. Hernandez and S. Stolfo Real-world data is dirty: Data cleansing and the merge/purge problem. Data Mining and Knowledge Discovery, 2(1): 9-37.
- [ME97] Alvaro E. Monge, Charles Elkan: An Efficient Domain-Independent Algorithm for Detecting Approximately Duplicate Database Records. In Proceedings of the Workshop on Research Issues on Data Mining and Knowledge Discovery (DMKD'97)

Felix Naumann | Workshop Datenreinigung | Winter 2009