Informationsintegration

Schema Matching

Ulf Leser

Inhalt dieser Vorlesung

- Schema Matching
  - Labelbasiert
  - Instanzbasiert
  - Strukturbasiert
- Erweiterungen
- Globales Matching

Schema Matching

- Korrespondenzen müssen irgendwo herkommen
- Finden von Korrespondenzen ist nicht trivial
  - Große Schemata: Viele Tabellen und Attribute
  - Generische, automatisch erzeugte Namen
  - Keine oder fehlerhaft umgesetzte Namenskonventionen
  - Fehlende Dokumentation
  - „Ungewöhnliche“ Schemata: Denormalisierung, Redundanzen etc.
  - Semantische Heterogenität: Synonyme, Homonyme, ...
  - Schematische Heterogenität
- Möglichkeiten
  - Manuelle Erstellung: Teuer, fehleranfällig, zeitraubend
  - Schema Matching: Automatisches Finden äquivalenter Elemente

Beispiele

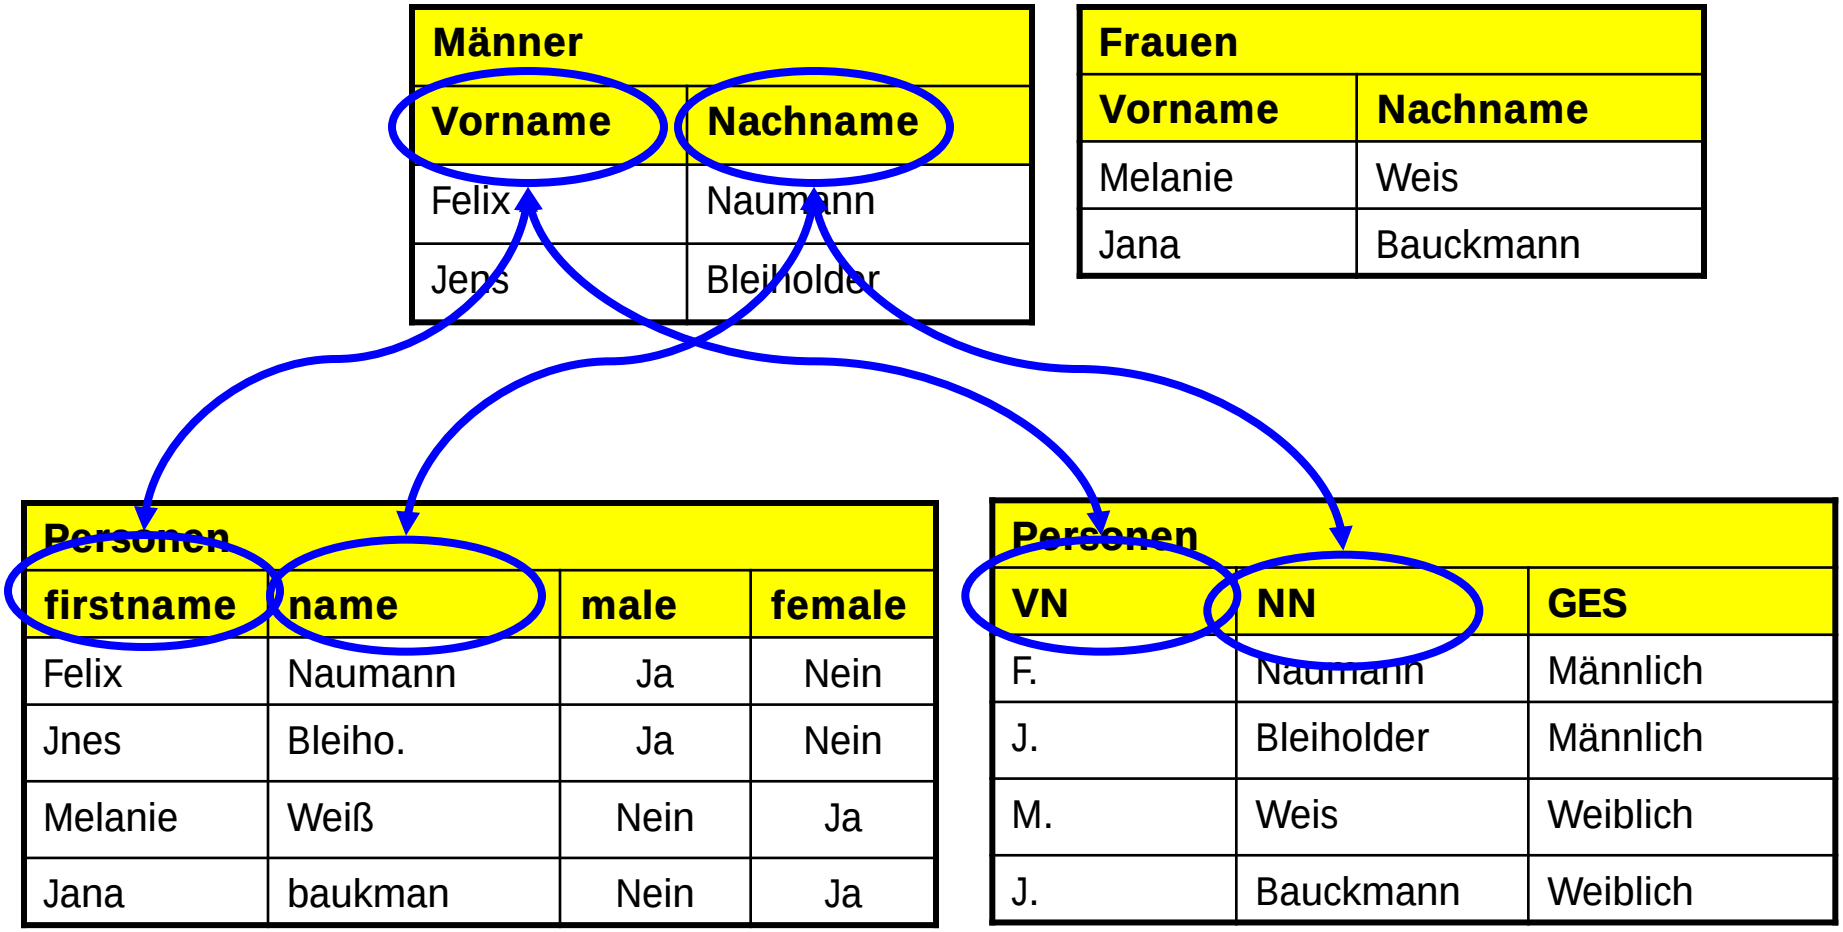

Männer	
Vorname	**Nachname**
Felix	Naumann
Jens	Bleiholder

Frauen	
Vorname	**Nachname**
Melanie	Weis
Jana	Bauckmann

Personen			
firstname	**name**	**male**	**female**
Felix	Naumann	Ja	Nein
Jnes	Bleiho.	Ja	Nein
Melanie	Weiß	Nein	Ja
Jana	baukman	Nein	Ja

Personen		
VN	**NN**	**GES**
F.	Naumann	Männlich
J.	Bleiholder	Männlich
M.	Weis	Weiblich
J.	Bauckmann	Weiblich

Woher wissen wir das?

- Attribute haben ähnliche Namen
- Ähnlicher Tabellenkontext
- Werte sehen nach Vor- oder Nachnamen aus
- Werte sehen ähnlich aus
- Wo Vornamen sind, sind meist auch Nachnamen
- Personen haben Vor- und Nachnamen
- Männer sind Personen ...
- Vieles davon erschließt sich dem Computer nicht ohne weiteres

Verfahren

- Wir betrachten die folgenden Verfahren näher
  - Labelbasiert: Verwendung der Namen der Schemaelemente
  - Instanzbasiert: Verwendung der eigentlichen Daten
  - Strukturbasiert: Ausnutzung der Struktur des Schemas
- Aktuelle Schema Matcher verwenden alle Methoden und noch einige mehr
  - Erkennen von Instanzduplikaten
  - Hinzuziehen von Hintergrundwissen (Ontologien)
  - Linguistische Analyse langer Werte (insb. bei Daten)

Labelbasiertes Schema Matching

- Geg. zwei Schemata mit Attributmengen A und B
  - A={ID, Name, Vorname, Alter}, B={No, Name, First_name, Age}
- Kernidee
  - Bilde Kreuzprodukt aller Attribute aus A und B
  - Für jedes Paar berechne die Ähnlichkeit der Attributnamen
    - Z.B. Editdistanz, Jaro-Winkler, ...
  - Die ähnlichsten Paare sind die Matches

	ID	Name	Vorname	Alter
No				
Name				
First_name				
Age				

Beispiel 2

- Geg. zwei Schemata mit Attributmengen A und B
  - A={ID, Name, Vorname, Alter}, B={No, Name, First_name, Age}
- Kernidee
  - Bilde Kreuzprodukt aller Attribute aus A und B
  - Für jedes Paar berechne die Ähnlichkeit der Attributnamen
    - Z.B. Editdistanz, Jaro-Winkler, ...
  - Die ähnlichsten Paare sind die Matches

	ID	Name	Vorname	Alter
No	2	3	6	5
Name	4	0	3	4
First_name	9	6	5	8
Age	3	3	5	3

Beispiel 3

- Geg. zwei Schemata mit Attributmengen A und B
  - A={ID, Name, Vorname, Alter}, B={No, Name, First_name, Age}
- Kernidee
  - Bilde Kreuzprodukt aller Attribute aus A und B
  - Für jedes Paar berechne die Ähnlichkeit der Attributnamen
    - Z.B. Editdistanz, Jaro-Winkler, ...
  - Die ähnlichsten Paare sind die Matches

	ID	Name	Vorname	Alter
No	2	3	6	5
Name	4	0	3	4
First_name	9	6	5	8
Age	3	3	5	3

Beispiel 4

- Geg. zwei Schemata mit Attributmengen A und B
  - A={ID, Name, Vorname, Alter}, B={No, Name, First_name, Age}
- Kernidee
  - Bilde Kreuzprodukt aller Attribute aus A und B
  - Für jedes Paar berechne die Ähnlichkeit der Attributnamen
    - Z.B. Editdistanz, Jaro-Winkler, ...
  - Die ähnlichsten Paare sind die Matches

	ID	Name	Vorname	Alter
No	2	3	6	5
Name	4	0	3	4
First_name	9	6	5	8
Age	3	3	5	3

Probleme

- Ambiguität: Mehrere gleichgute Matches
  - Gerade bei kurzen Labels – sparen Schreibarbeit beim Entwickeln
- Verfahren ist nicht symmetrisch
- Semantik der Label wird nicht berücksichtigt
  - Synonyme und Homonyme
- Abkürzungen, Fremdsprachen, zusammengesetzte Namen
  - id_pers_abt : Entwickler lieben kurze Namen
- Matched Attribute, ignoriert Zugehörigkeit zu Relationen
- Fazit: Funktioniert nicht gut
  - Z.B.: dist(ID_Name, Name)=3, dist(ID_Name, ID_Nase)=1
  - Umso schlechter, je weniger „sprechend“ Attributnamen sind
  - Trotzdem Stand der Technik in vielen kommerziellen Produkten

Einfache Erweiterung auf Relationen / Schemata

- Berechne paarweise Ähnlichkeiten für alle Attribute
  - Über alle Relationen hinweg
- Berechne paarweise Ähnlichkeit der Relationennamen
- Zweistufiges Verfahren
  - Berechne Matching der Relationen – aggregierter Score aus Ähnlichkeiten der Relationennamen und der Attributmengen
  - Berechne Matching der Attribute nur innerhalb der gematchten Relationenpaare
- Geht besser – siehe Similarity Flooding

Inhalt dieser Vorlesung

- Schema Matching
  - Labelbasiert
  - Instanzbasiert
  - Strukturbasiert
- Erweiterungen
- Globales Matching

Instanzbasiertes Schema Matching

- Geg. Instanzen zweier Tabellen mit Attributmengen A und B
- Kernidee
  - Für jedes Attribut: Extrahiere interessante Eigenschaften der Werte
    - Beispielwerte, maximale Werte, Durchschnitt, Buchstabenhäufigkeiten, Länge, statistische Eigenschaften, etc.
    - Menge aller Werte ist auch eine interessante Eigenschaft
  - Bilde Kreuzprodukt aller Attribute aus A und B
  - Berechne Ähnlichkeit der Attribute als Ähnlichkeit der Eigenschaften

Beispiel

ID	Name	Whg
1	Müller	Danziger Str, Berlin
2	Meyer	Boxhagenerstr, Berlin
4	Schmidt	Turmstr, Köln

Nr	Adresse	Telefon
1	Seeweg, Berlin	030-3324566
3	Aalstr, Schwedt	0330-1247765
4	Rosenallee, Kochel	0884-334621

- Eigenschaften: Datentyp, durchschnittliche Länge
  - A = {(NUM, 1), (STRING, 6), (STRING, 18)}
  - B = {(NUM, 1), (STRING, 16), (STRING, 11)}
- Ähnlichkeit: Euklidischer Abstand d (NUM=0, STR=1)

	ID	Name	Whg
Nr	d(<0,1>,<0,1>)	d(<1,6>,<0,1>)	d(<1,18>,<0,1>)
Adresse	d(<0,1>,<1,16>)	d(<1,6>,<1,16>)	d(<1,18>,<1,16>)
Telefon	d(<0,1>,<1,11>)	d(<1,6>,<1,11>)	d(<1,18>,<1,11>)

Probleme

- Ambiguität: Mehrere gleichgute Matches
- Welche Eigenschaften wählen?
- Wie sollen Eigenschaften verglichen werden?
  - Z.B. vektorbasiert: Cosinus der Winkel, Euklidischer Abstand, ...
  - Z.B. numerisch: Mittelwert, Abstandsverteilungen, ...
- Abstandsmaße sind domänenabhängig
  - Abstand zwischen Datums, Geldbeträgen, Straßennamen, ...
- Gleiche Werte müssen nicht gleiche Semantik bedeuten
  - Telefon /Faxnummer; Surrogate-Keys; Mitarbeiter / Kundennamen
- Fazit: Funktioniert manchmal, manchmal nicht
  - Gut bei mittellangen Stringwerten (keine kompletten Texte)

Verfeinerung: Duplikatbasiertes Matching [BN05]

- Klassisches instanzbasiertes Matching ist vertikal
  - Vergleich kompletter Spalten
  - Ignoriert die Zusammengehörigkeit von Werten zu Tupeln

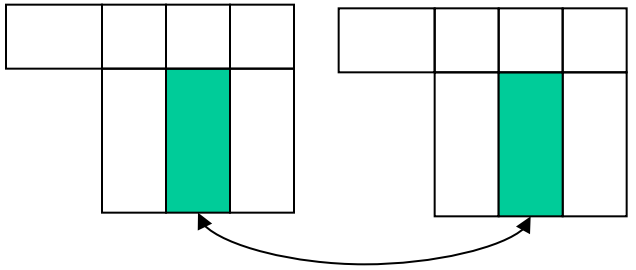

- Horizontales instanzbasiertes Matching
  - Vergleicht paarweise alle Tupel
  - Finde (einige) potentielle Duplikate
  - In den Duplikaten müssen die einzelnen Attributwerte nahezu identisch sein
  - Ergibt ein Attributmatching pro Duplikat
  - Finales Matching z.B. durch Majority Voting

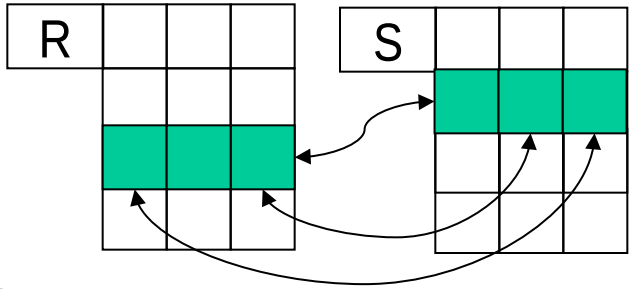

Beispiel

A	B	C	D	E
Max	Michel	m	601- 4839204	601- 4839204
...	...	..	...	...

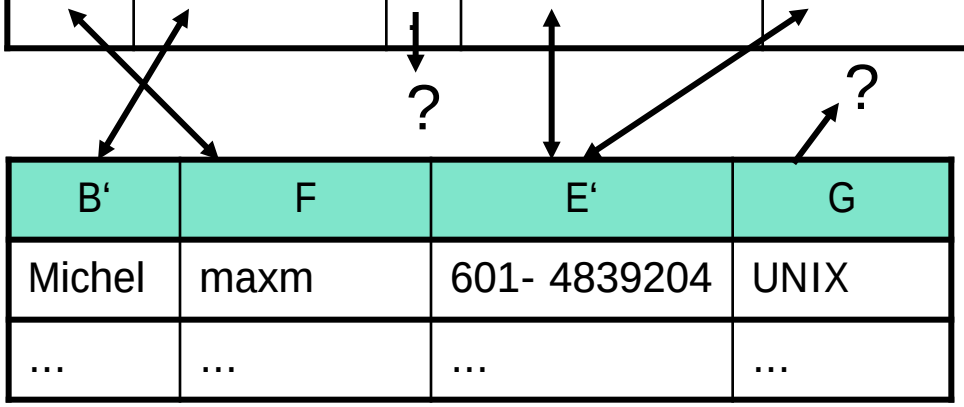

B‘	F	E‘	G
Michel	maxm	601- 4839204	UNIX
...	...	...	...

- Matching nach einem Duplikat

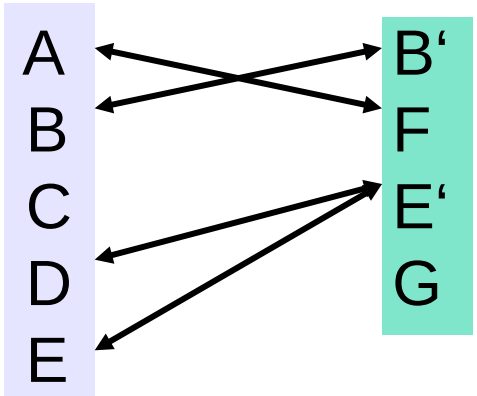

Beispiel 2

A	B	C	D	E
Max	Michel	m	601- 4839204	601- 4839204
Sam	Adams	m	541- 8127100	541- 8121164

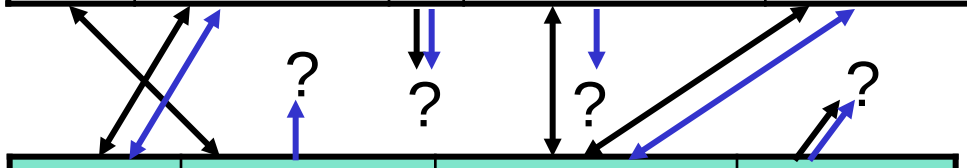

B‘	F	E‘	G
Michel	maxm	601- 4839204	UNIX
Adams	beer	541- 8127164	WinXP

Matching nach zwei Duplikaten

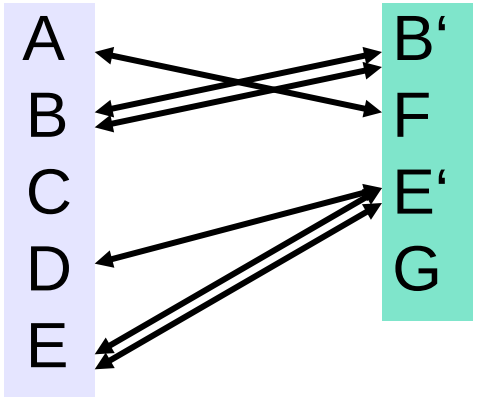

Probleme

- Funktioniert nur, wenn Duplikate vorhanden sind
  - Das ist starke Einschränkung; Relationen müssen erst sehr präzise gematched werden
- Schwierigkeiten bei großer struktureller Heterogenität
  - Gleiche Attribute sehr unterschiedlich auf Relationen verteilt
- Duplikaterkennung setzt idR Korrespondenzen voraus
- Duplikaterkennung ist teuer (später)
- Aber: Kann sehr ähnliche Attribute korrekt trennen
  - Telefonnummern<>Faxnummern , Nachname<>Geburtsname
- Fazit: Funktioniert sehr gut, wenn erkennbare Duplikate vorhanden

Inhalt dieser Vorlesung

- Schema Matching
  - Labelbasiert
  - Instanzbasiert
  - Strukturbasiert
- Erweiterungen
- Globales Matching

Probleme

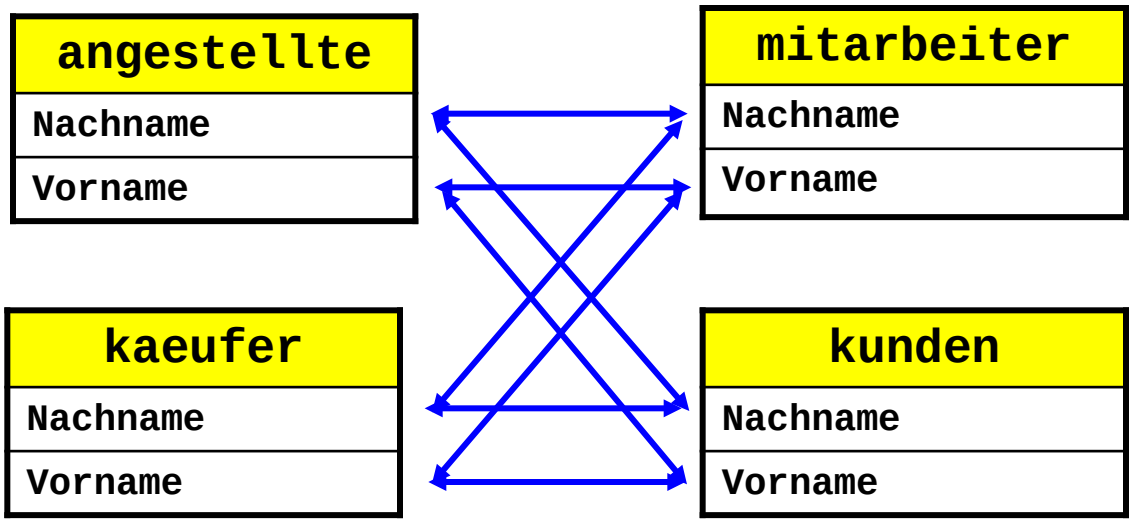

- Attribut-Attribut-Matching
  - Instanzbasiert: Wertecharakteristika sehr ähnlich
  - Labelbasiert: Attributnamen sehr ähnlich
  - Alle Matchings etwa gleich gut

Besser

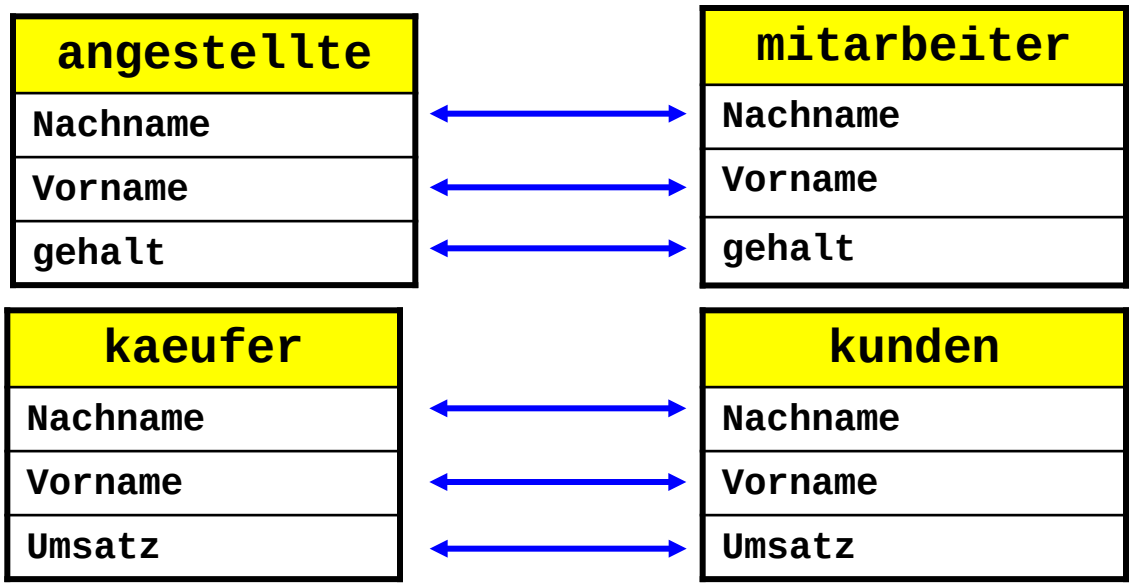

- Kontext der Attribute ausnutzen
- Attribute einer Relation sind auch im anderen Schema gerne (nicht immer) in einer Relation

Abfärben

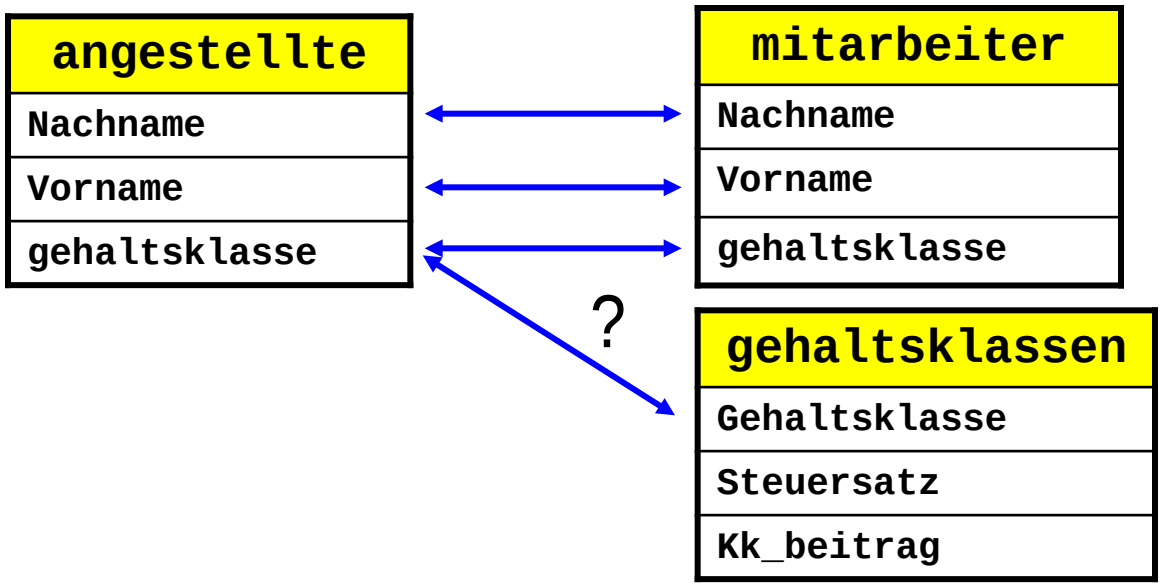

- Attributmatchings so wählen, dass Quellen und Ziele in jeweils einer Tabelle liegen
- Ähnlichkeit „benachbarter“ Attribute verstärkt Evidenz
  - „färbt ab“

Similarity Flooding [MGMR02]

- Geg. zwei Schemata mit Relationen, Attributen, FK-PK Beziehungen und Datentypen
  - Wir benutzen jetzt sehr viele Evidenzen
- Kernidee
  - Vergleiche alle Attributpaare und finde Match-Kandidaten
  - Nutze alle Beziehungen zwischen Schemaelementen zur Auswahl des finalen Matchings
    - Attribute gehören zur selben Relation
    - Attribute haben denselben Datentyp
    - Attribute sind PK-FK-Paar
    - Relationen sind durch PK-FK verbunden

Übersicht

- Umwandlung der zwei Schemata in Graphen R, S
- Berechnung initialer Ähnlichkeit zwischen allen Elementen
  - Attribute und Relationennamen
  - Z.B. label- oder instanzbasiert
- Ausnutzen des Kontext
  - Seien P=(A1,A2) und Q=(B1,B2) Matching-kandidaten mit A1,B1 aus R, A2, B2 aus S
  - Seien A1, B1 Nachbarn in R und A2, B2 Nachbarn in S
    - z.B. Attribute derselben Relation oder FK/PK Paar
  - Dann verstärken sich die Ähnlichkeiten von P, Q wechselseitig
  - Ähnlichkeit zwischen Nachbarn „färbt ab“
- Formulierung als Flussproblem in einem Graphen
- Optimale Lösung durch iterativen Algorithmus

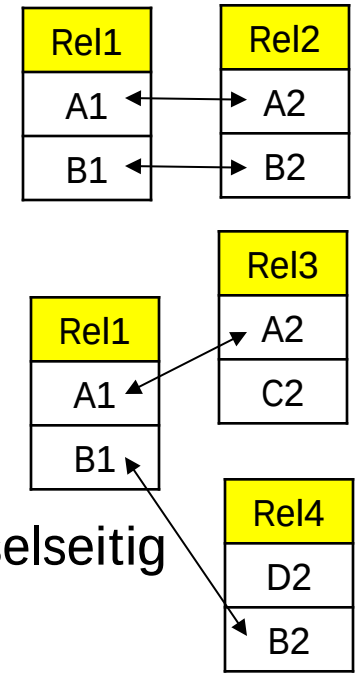

Schema -> Graph

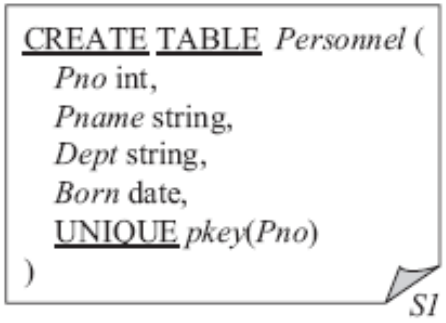

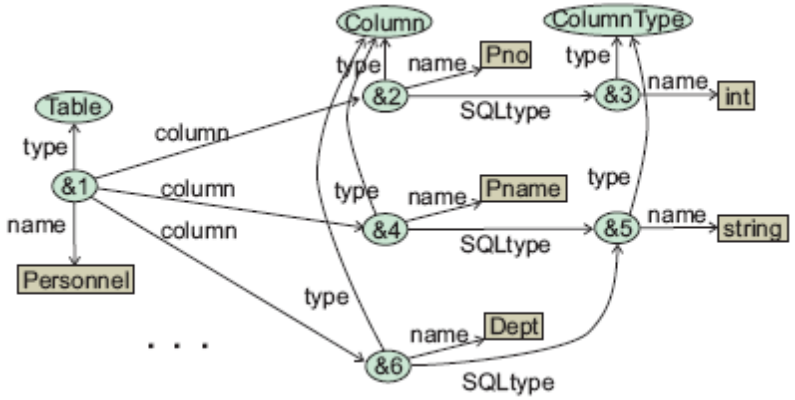

- &-Knoten repräsentieren Relationen und Attribute
- Deren Eigenschaften sind verbundene Knoten
  - Namen, Datentypen, ...
- Art der Beziehung definiert durch Kantenlabel
  - Column_of, Type, SQLType, Name, FK-PK

Kandidaten für Matchings

- Konstruktion des Pairwise Connectivity Graph (PCG)
  - Sei (x, p, x‘)∈R und (y, p, y‘)∈S → Füge ((x,y), p, (x‘,y‘)) zu PCG
  - Knoten im PCG sind Paare von Elementen aus beiden Schemata
  - Es werden nur solche Paare betrachtet, die in den beiden Schemata mindestens durch eine Kante gleichen Typs verbunden sind
    - Einschränkung des Suchraums

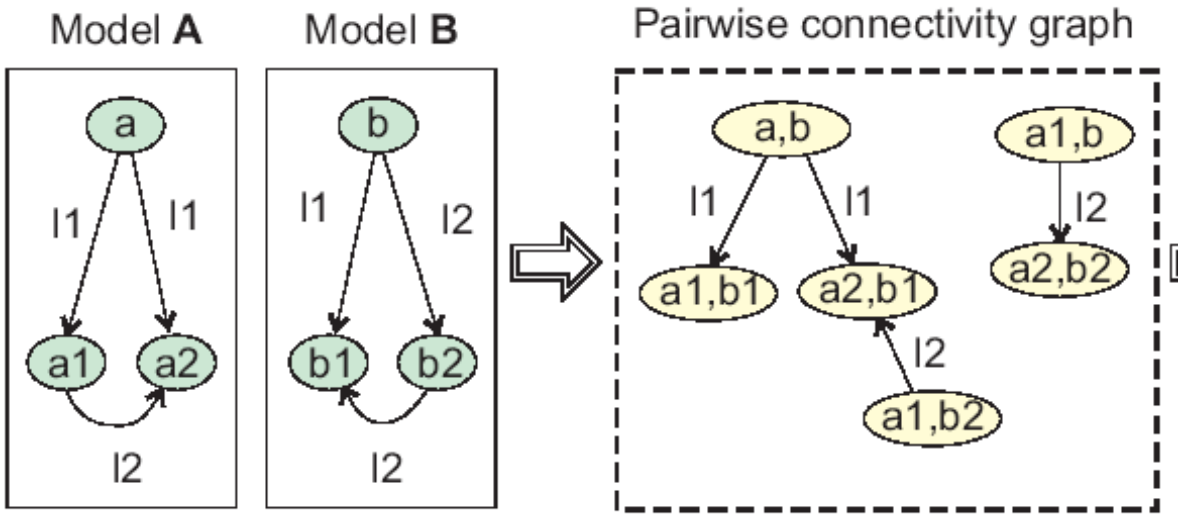

Kantengewichte

- Im PCG sind alle Elementpaare Nachbarn, die in beiden Schemata Nachbarn sind
- Kanten werden nach Art der Kante gewichtet
  - Muss nicht symmetrisch sein (z.B. substring_of())

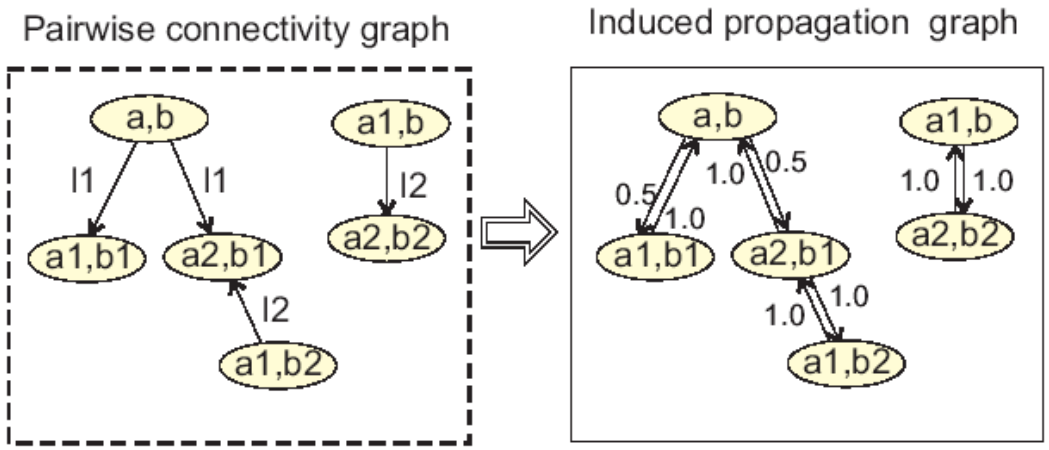

Flussidee

- Knoten sind sich auch ähnlich
  - Ähnlichkeit der Elemente (Label, Instanzen, Datentyp ...)
- Knoten erben außerdem die Ähnlichkeit ihrer Nachbarn
  - Über die gewichteten Kanten
- Idealerweise befindet sich der Graph in einem Gleichgewicht
- Finde Knotengewichte so, dass sie sich als Summe der Ausgangsgewichte (initiale Ähnlichkeit) und der (kanten-gewichteten) Gewichte ihrer Nachbar darstellen lassen

Lösungsverfahren

- Iteratives Lösungsverfahren (sketch)
  - Addiere zu jedem Knoten die (gewichteten) Gewichte seiner Nachbarn
  - Normiere alle Knotengewichte im Graphen mit dem maximalen Gewicht
  - Iteriere, bis Summe aller Änderungen kleiner als gegebener Schwellwert
- Knoten mit höchsten Scores sind die Lösung

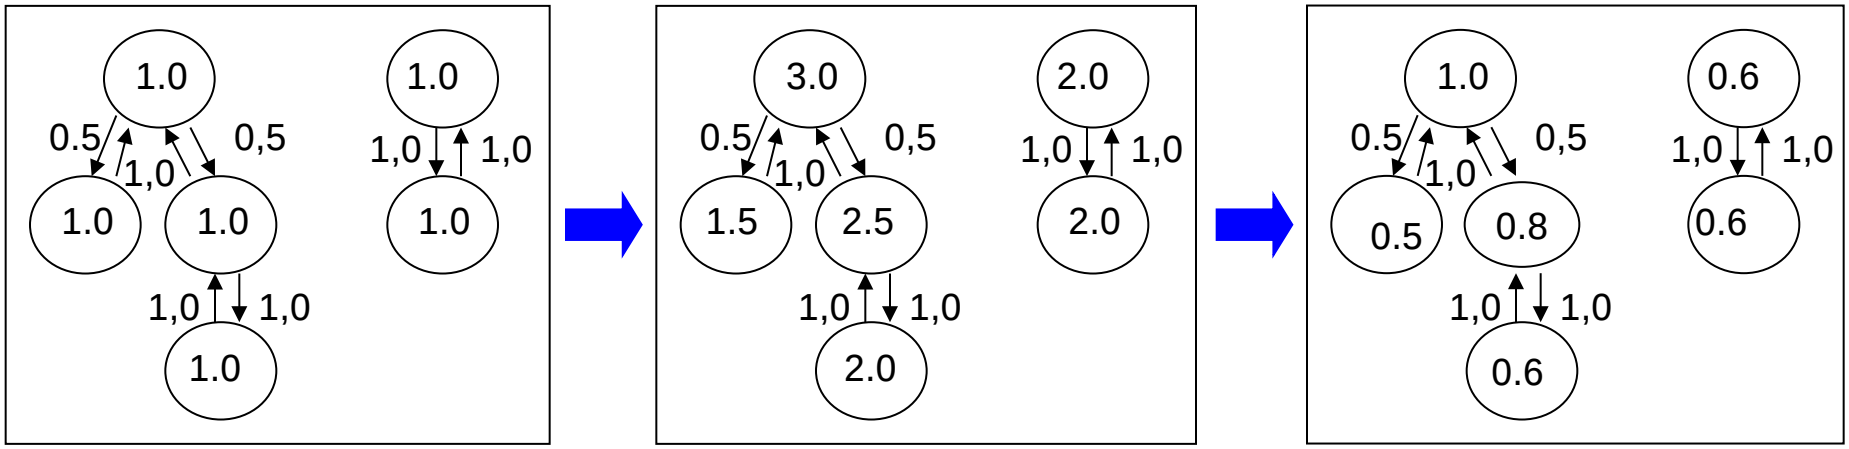

Probleme

- Benötigt andere Verfahren für initiale Ähnlichkeiten
- Viele Parameter
  - Welche Kanten? Welche Kantengewichte? Wie lange iterieren?
- Kann u.U. langsam konvergieren
- Fazit: Wichtige Ergänzung zu den bisherigen Verfahren

Inhalt dieser Vorlesung

- Schema Matching
  - Labelbasiert
  - Instanzbasiert
  - Strukturbasiert
- Erweiterungen
- Globales Matching

Mischformen

- Hybrid
  - Integrierte Anwendung mehrerer Verfahren
  - Bsp: Instance-based + Datentypen
- Ensembles
  - Repertoire bekannter Verfahren
  - Zunächst unabhängige Anwendung
  - Dann (gewichtete) Kombination der Ergebnisse
  - Gewichte kann man lernen

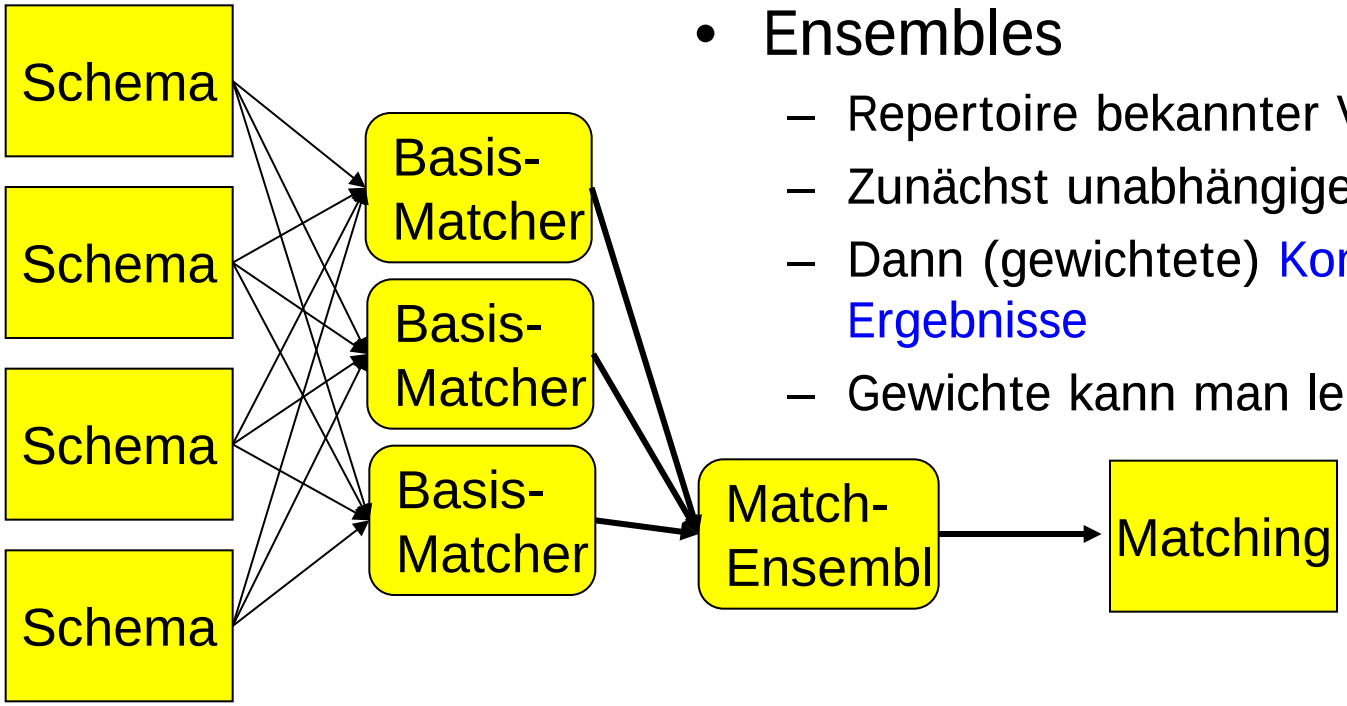

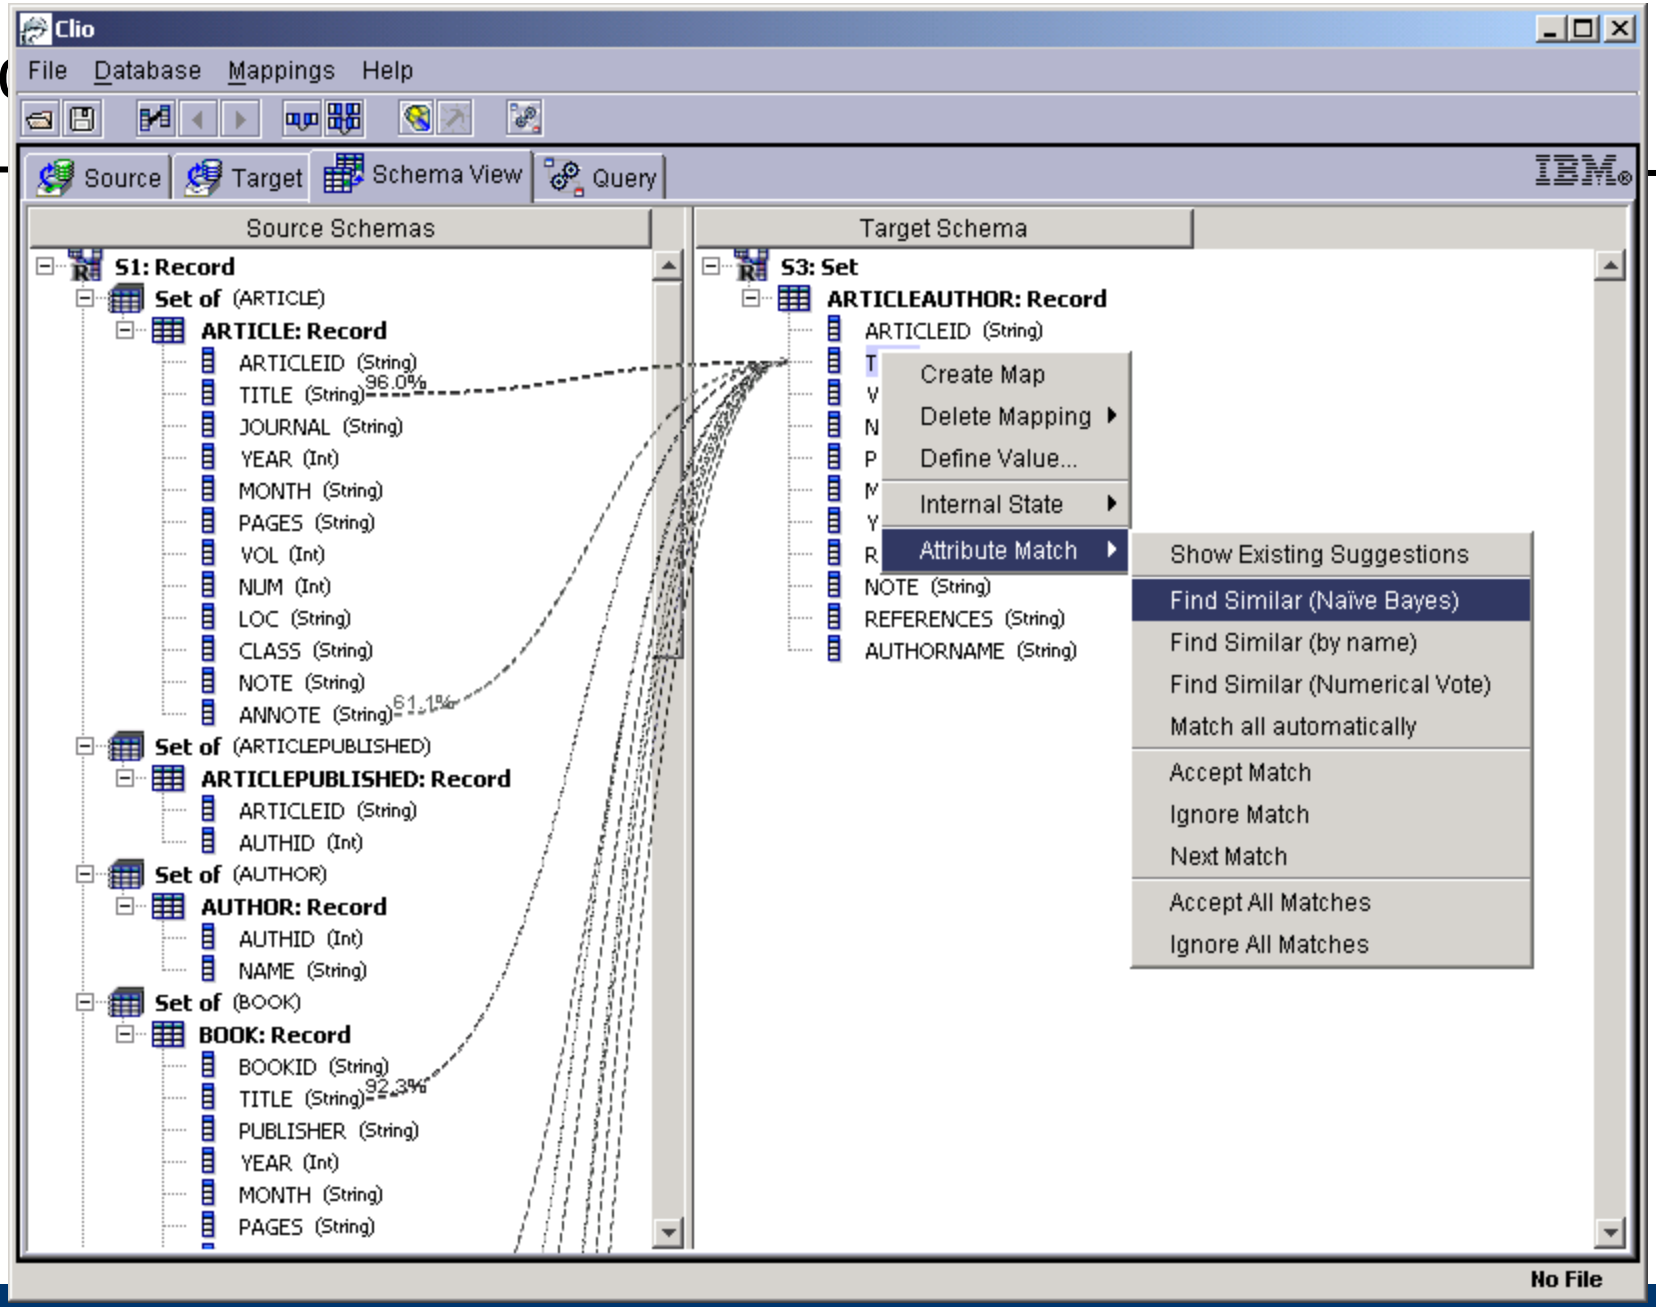
Clio
File Database Mappings Help
Source Target Schema View Query
IBM
Source Schemas
S1: Record
Set of (ARTICLE)
ARTICLE: Record
ARTICLEID (String)
TITLE (String)
96.0%
JOURNAL (String)
YEAR (Int)
MONTH (String)
PAGES (String)
VOL (Int)
NUM (Int)
LOC (String)
CLASS (String)
NOTE (String)
ANNOTE (String)
61.1%
Set of (ARTICLEPUBLISHED)
ARTICLEPUBLISHED: Record
ARTICLEID (String)
AUTHID (Int)
Set of (AUTHOR)
AUTHOR: Record
AUTHID (Int)
NAME (String)
Set of (BOOK)
BOOK: Record
BOOKID (String)
TITLE (String)
92.3%
PUBLISHER (String)
YEAR (Int)
MONTH (String)
PAGES (String)
Target Schema
S3: Set
ARTICLEAUTHOR: Record
ARTICLEID (String)
NOTE (String)
REFERENCES (String)
AUTHORNAME (String)
Create Map
Delete Mapping
Define Value...
Internal State
Attribute Match
Show Existing Suggestions
Find Similar (Naïve Bayes)
Find Similar (by name)
Find Similar (Numerical Vote)
Match all automatically
Accept Match
Ignore Match
Next Match
Accept All Matches
Ignore All Matches
No File

Match-Granularität

- Bisher sind die Matchings immer 1:1
- Es gibt aber oft m:n, n:1 und 1:n Matches
- Wie soll man Werte aufbrechen / reorganisieren?
  - Viele Funktionen denkbar

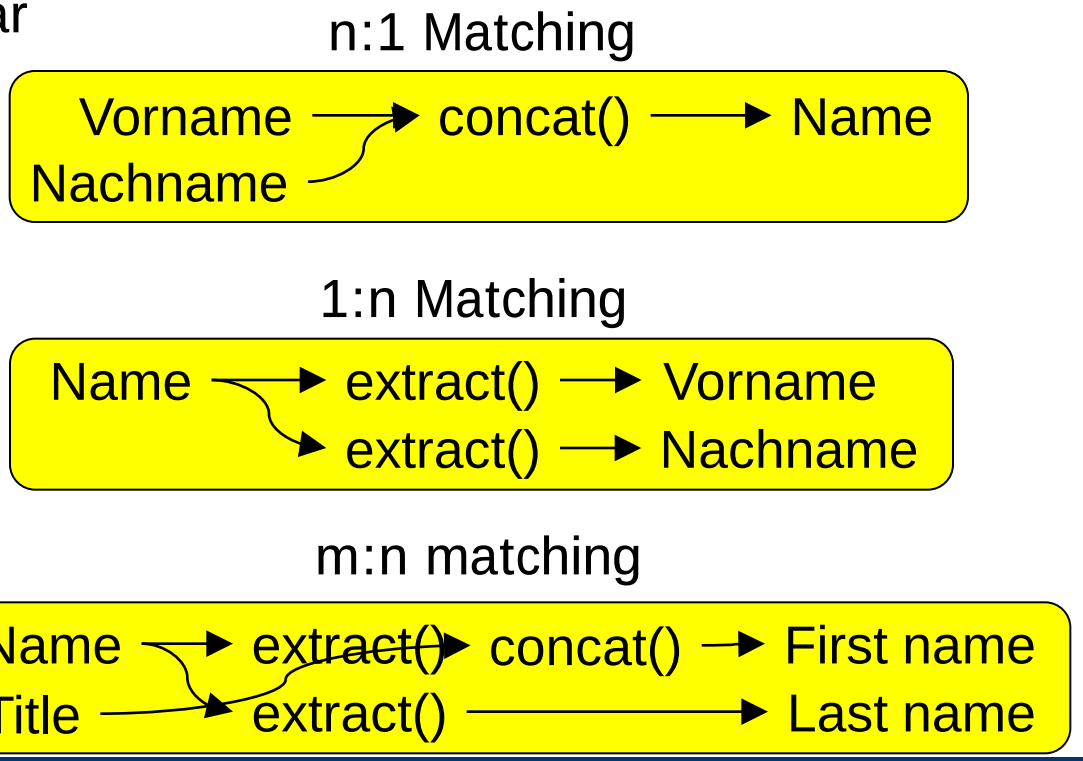

Inhalt dieser Vorlesung

- Schema Matching
- Erweiterungen
- Globales Matching

Globales Matching

- Bisher: jedes Attributmatching individuell entscheiden
- Tatsächlich will man aber Schemata aufeinander abbilden
- Schemamatching ergibt sich nicht einfach aus besten Attributmatchings
  - Muss kein Fehler sein:
    C könnte PK und D ein FK dazu sein

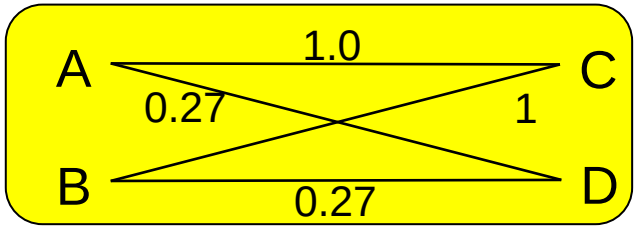

- Globales Matching
  - Menge von disjunkten Attributmatchings, die global optimal ist
  - Klassische Formulierung: Finde maximales bipartites Matching
  - Alternative: Stable Marriage

Stable Marriage

- Gegeben: n Frauen und m Männer
  - Zwei Attributlisten
- Monogamie: Je eine Frau kann nur mit einem Mann verheiratet sein und umgekehrt
  - Nur 1:1 Matchings
- Präferenzen: Jede Frau hat eine Rangliste ihrer bevorzugten Männer und umgekehrt
  - Attribut-Ähnlichkeit nach beliebigem Verfahren
- Gesucht: Stabile Ehen
  - Es darf keine Paare geben, für die gilt: f1 heiratet m1, f2 heiratet m2, aber f1 bevorzugt m2 und m2 bevorzugt f1
  - Diese Ehe wäre instabil

Beispiel 1

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

Quelle: David Toth, "The Stable Marriage Problem: More Marital Happiness than Reality TV" , April 25, 2003, Connecticut College, New London, CT, USA,

Beispiel 2

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)

Beispiel 3

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)
- 2 stellt Antrag an C, sie willigt ein: (1, B) (2, C)

Beispiel 4

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)
- 2 stellt Antrag an C, sie willigt ein: (1, B) (2, C)
- 3 stellt Antrag an B, sie willigt ein & verlässt 1: (2, C) (3, B)

Beispiel 5

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)
- 2 stellt Antrag an C, sie willigt ein: (1, B) (2, C)
- 3 stellt Antrag an B, sie willigt ein & verlässt 1: (2, C) (3, B)
- 1 stellt Antrag an D, sie willigt ein: (1, D) (2, C) (3, B)

Beispiel 6

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)
- 2 stellt Antrag an C, sie willigt ein: (1, B) (2, C)
- 3 stellt Antrag an B, sie willigt ein & verlässt 1: (2, C) (3, B)
- 1 stellt Antrag an D, sie willigt ein: (1, D) (2, C) (3, B)
- 4 stellt Antrag an D, sie lehnt ab: (1, D) (2, C) (3, B)

Beispiel 7

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- 1 stellt Antrag an B, sie willigt ein: (1, B)
- 2 stellt Antrag an C, sie willigt ein: (1, B) (2, C)
- 3 stellt Antrag an B, sie willigt ein & verlässt 1: (2, C) (3, B)
- 1 stellt Antrag an D, sie willigt ein: (1, D) (2, C) (3, B)
- 4 stellt Antrag an D, sie lehnt ab: (1, D) (2, C) (3, B)
- 4 stellt Antrag an A, sie willigt ein: (1, D) (2, C) (3, B) (4, A)

Beispiel Ende

Männer (1-4)	Frauen (A-D)
1: B, D, A, C	A: 2, 1, 4, 3
2: C, A, D, B	B: 4, 3, 1, 2
3: B, C, A, D	C: 1, 4, 3, 2
4: D, A, C, B	D: 2, 1, 4, 3

- Damit haben wir vier stabile Paare

Algorithmus [GS62]

- Vorgehen war Greedy: Gale-Shapely Algorithmus
  - Findet garantiert eine stabile Lösung (aber nicht die optimale)
  - Bei gleicher Zahl Männer/Frauen gibt es immer eine stabile Lösung

```
function stableMatching {
  Initialize all m ∈ M and w ∈ W to free;
  while ∃ free man m who still has a woman w to propose to {
    w = m's highest ranked such woman to whom he has not yet proposed;
    if w is free
      (m, w) become engaged
    else some pair (m', w) already exists
      if w prefers m to m'
        (m, w) become engaged
        m' becomes free
    else
      (m', w) remain engaged
  }
}
```

Bipartites Matching – Stable Marriage

- Stable Marriage benötigt Rangordnung und keine numerischen Gewichte
  - Konkrete Werte sind oft ziemlich arbiträr
  - Ordnungen sind stabiler als konkrete Werte
- Stable Marriage liefert i.d.R. nicht die optimale Lösung im Sinne eines bipartiten Matchings
- Bipartites Matching führt i.d.R. nicht zu einer im Sinne des Stable Marriage Problems stabilen Lösung
- Komplexität
  - Bipartites Matching: $O(n^{2*}\log(n))$, z.B. ungarischer Algorithmus
  - Stable Marriage: $O(n^2)$, z.B. Gale-Shapley

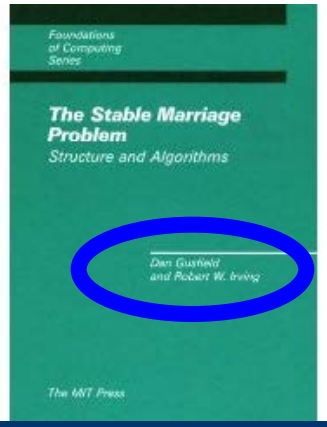

Literatur

- [RB01] Rahm, Bernstein. A survey of approaches to automatic schema matching. VLDB Journal 10(4), 2001
- [BN05] Bilke, Naumann. Schema Matching using Duplicates. ICDE 2005
- [MGMR02] Melnik, Garcia-Molina, Rahm: Similarity Flooding: A Versatile Graph Matching Algorithm and Its Application to Schema Matching. ICDE 2002
- [MH03] Madhavan, Halevy: Composing Mappings Among Data Sources. VLDB 2003
- [GS62] Gale, D. and Shapley, L. S. (1962). "College Admissions and the Stability of Marriage." *American Mathematical Monthly* ***69: 9-14.***