Schema Matching

Komplexe Informationssysteme

Fabian Panse

panse@informatik.uni-hamburg.de

Universität Hamburg

Universität Hamburg

DER FORSCHUNG | DER LEHRE | DER BILDUNG

Schema Matching

Schema Matching – Problemstellung

- Gegeben: Zwei Datenbankinstanzen mit jeweiligem Schema
- Gesucht: Mapping zwischen den zwei Schemata
- Vorgehensweise:
  1. Finden von Korrespondenzen zwischen den Elementen beider Schemata (Schema Matching)
  2. Ableitung eines Mappings von den gefundenen Korrespondenzen (Schema Mapping)

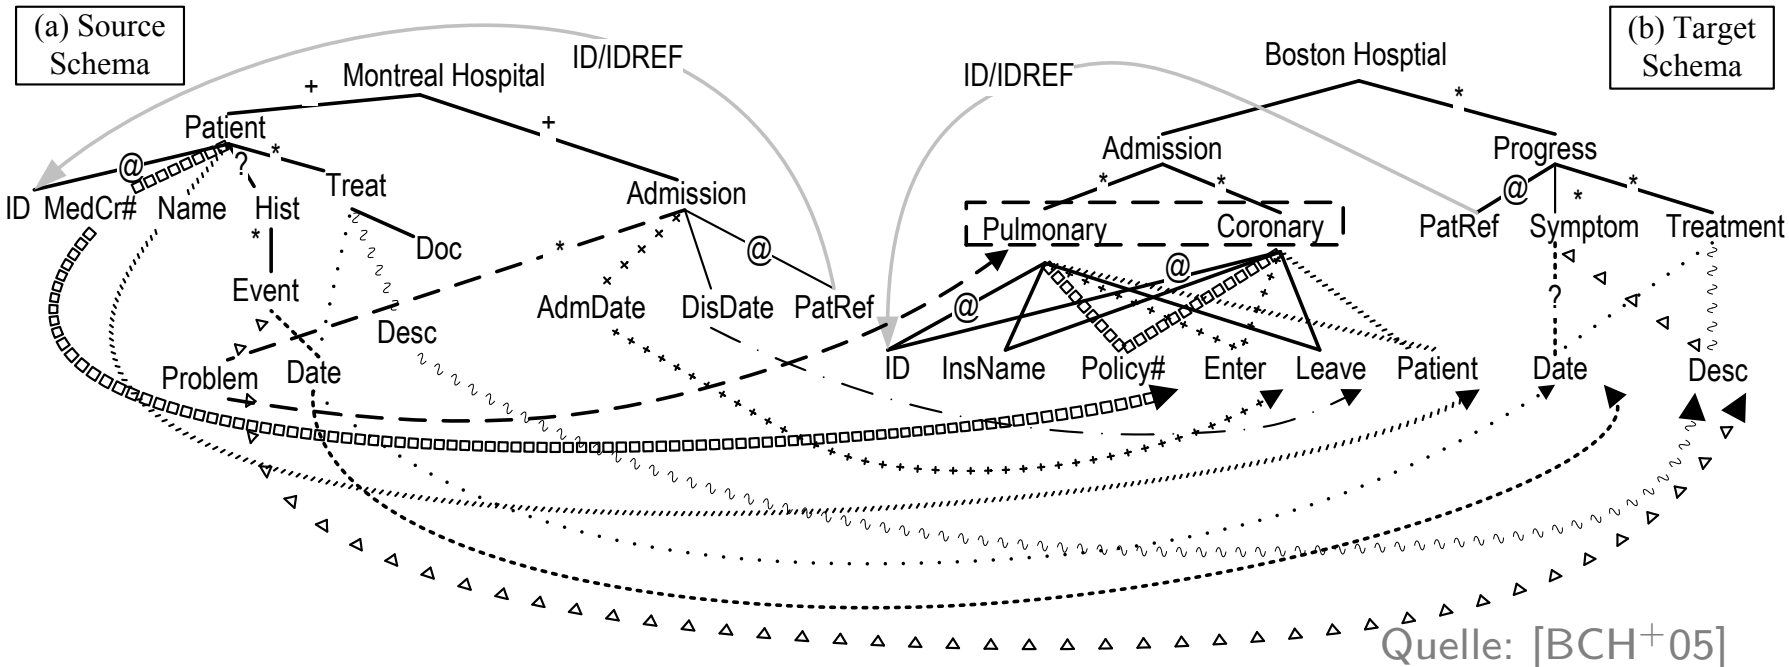

Quelle: [BCH+05]

Arten von Schema Matching Szenarien

- Bottom-Up:
  - Matching zwischen zwei Quellschemata
  - Globales Schema resultiert aus Integration der Quellschemata
  - Typisch für materialisierte Integration (z.B. Data Warehouse)
- Top-Down:
  - Matching zwischen globalem und Quellschema
  - Globales Schema ist von außen vorgegeben
  - Typisch für virtuelle Integration

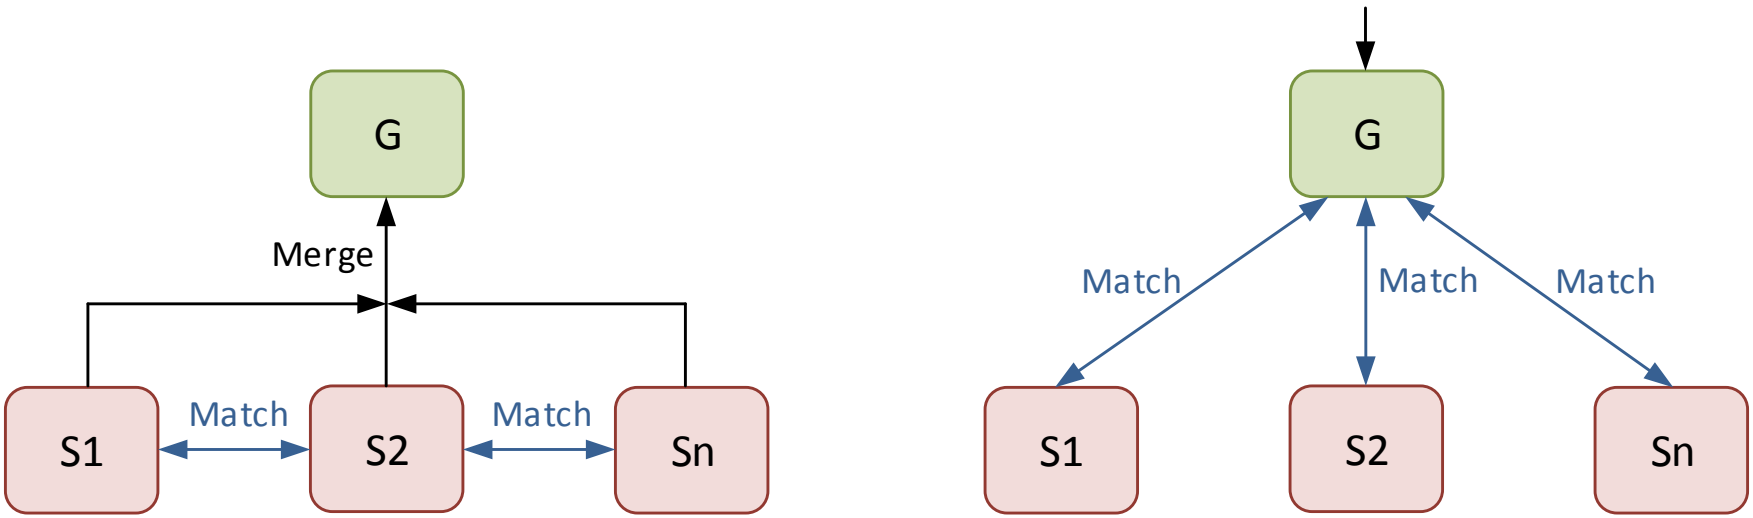

Arten von Schema Korrespondenzen

1:1 Korrespondenz

n:1 Korrespondenz

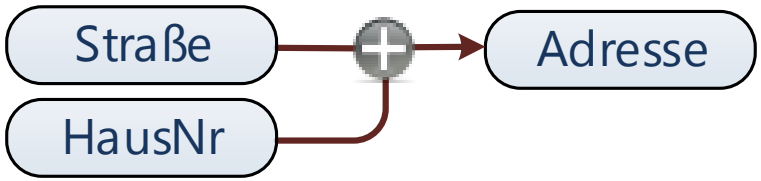

1:n Korrespondenz

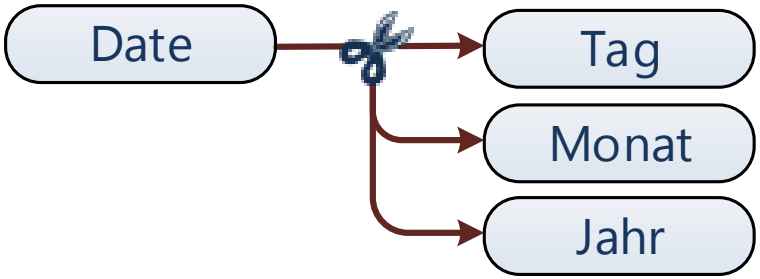

n:m Korrespondenz

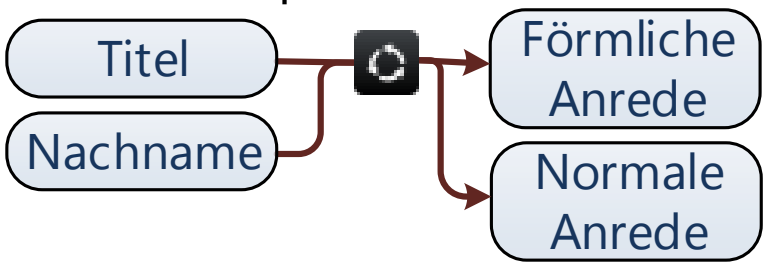

Quelle: Felix Gessert, Schema Matching - Semiautomatische Matching Verfahren und ihre Algorithmen

Schema Matching – Motivation

- Große Schemas
  - $>$ 100 Tabellen, viele Attribute
  - Bildschirm nicht lang genug
- Unübersichtliche Schemas
  - Tiefe Schachtelungen
  - Fremdschlüssel
  - Bildschirm nicht breit genug
  - XML Schema
- Fremde Schemas
  Unbekannte Synonyme
- Irreführende Schemas
  Unbekannte Homonyme
- Fremdsprachliche Schemas
- Kryptische Schemas
  - Attributnamen $<$ 8 Zeichen
  - Tabellennamen $<$ 8 Zeichen

Komplexe Schemata

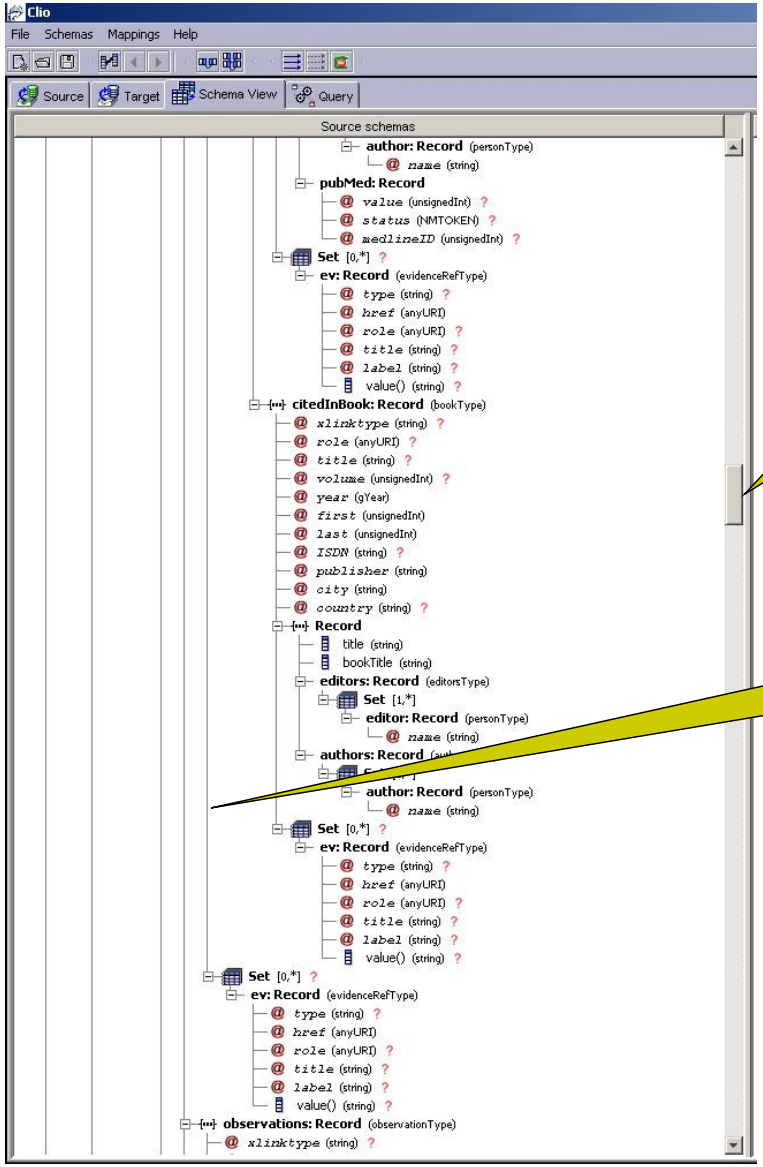

Man beachte die Scrollbar!

Man beachte die Schachtelungstiefe!

Schema Matching Systeme

Aufbau von Schema Matching Systemen

Ausgelegt für das Finden von 1:1 Korrespondenzen

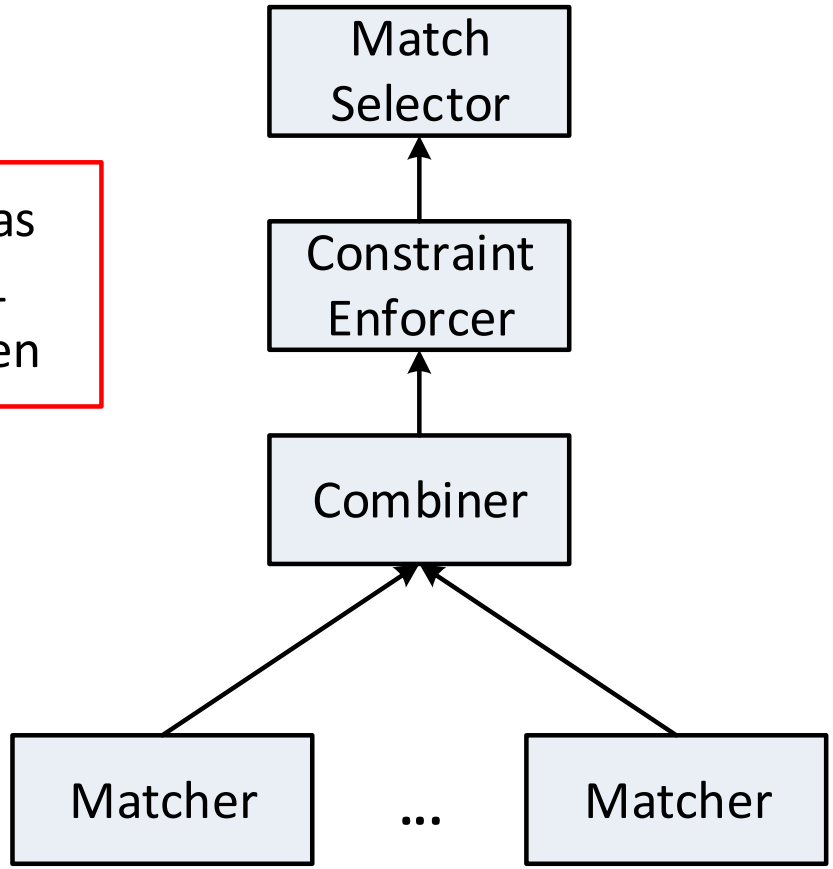

Aufbau von Schema Matching Systemen

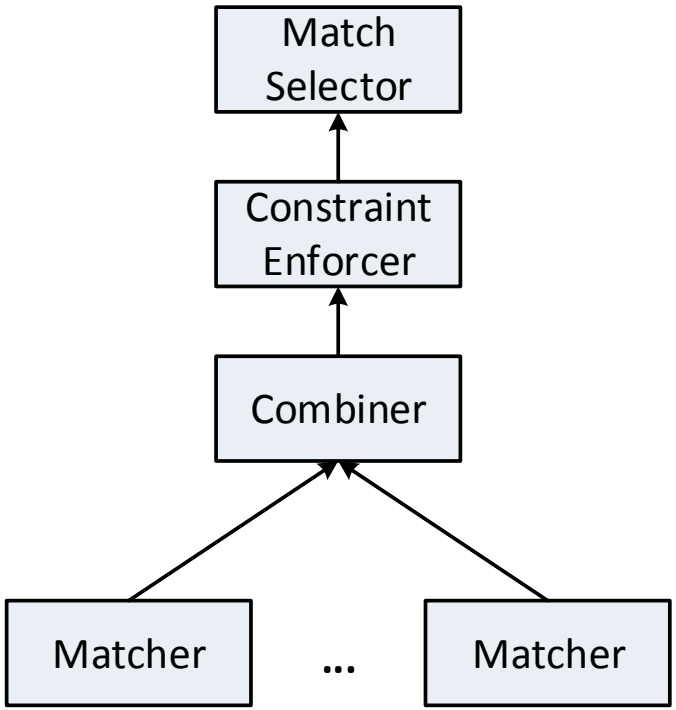

Matchers

- Input: Schemata $\mathcal{A}$ und $\mathcal{B}$
- Output: Ähnlichkeitsmatrix (eine Ähnlichkeit pro Paar $\{(a, b) \mid a \in \mathcal{A}, b \in \mathcal{B}\}$)
- Verschiedene Arten von Matchern die alle auf anderen Ideen basieren (vergleichbar mit Ähnlichkeitsmaßen für Stringwerte)

Aufbau von Schema Matching Systemen

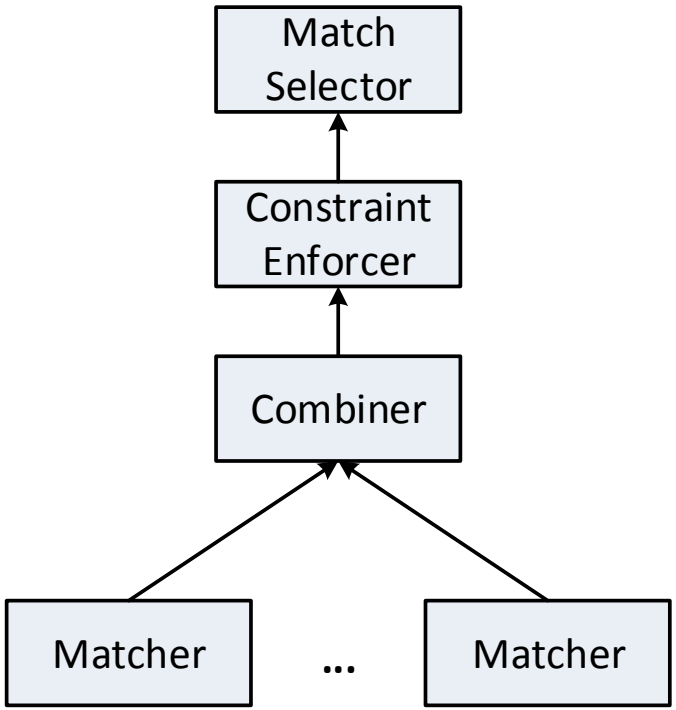

Combiner

- Input: eine Menge an Ähnlichkeitsmatrizen
- Output: eine einzige Ähnlichkeitsmatrix
- Kombiniert die Ergebnisse der einzelnen Matcher zu einem einzelnen
- Breites Spektrum:
  - primitiv (Durchschnittsberechnung)
  - komplex (gelernt oder handgefertigte Skripte)

Aufbau von Schema Matching Systemen

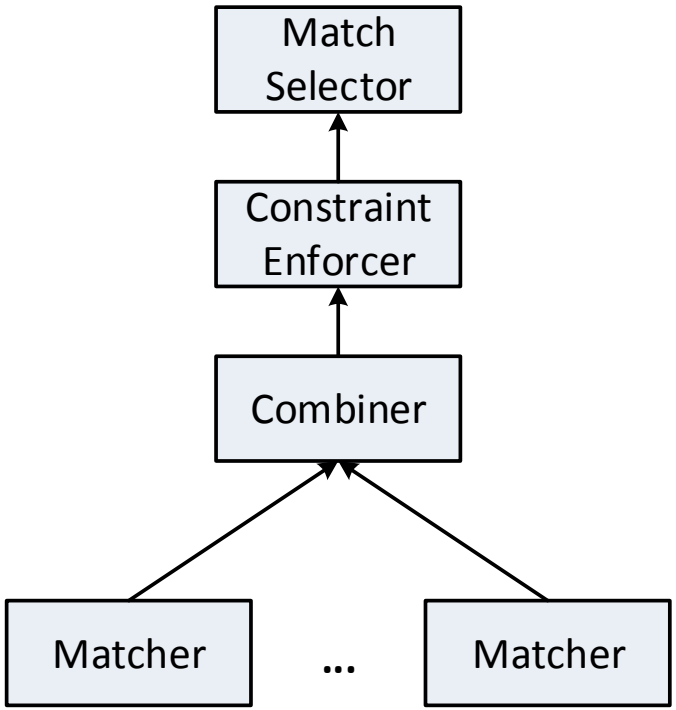

Constraint Enforcer

- Input: eine Ähnlichkeitsmatrix, eine Menge an Constraints
- Output: eine Ähnlichkeitsmatrix
- Einführung von Kontextwissen durch Ändern der Ähnlichkeitsmatrix

Aufbau von Schema Matching Systemen

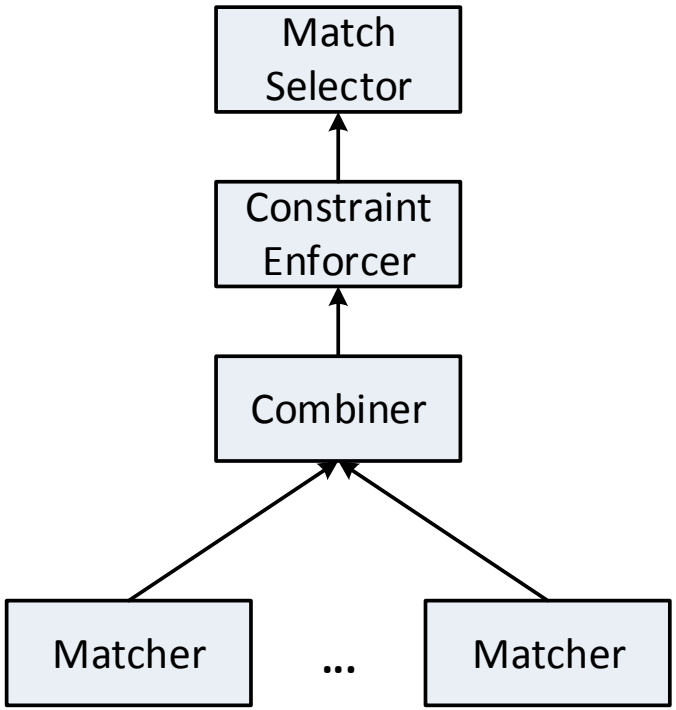

Match Selector

- Input: eine Ähnlichkeitsmatrix
- Output: eine Menge an Korrespondenzen
- Benutzt die paarweise berechneten Ähnlichkeiten um eine (aufeinander abgestimmte) Menge an Korrespondenzen zu berechnen
- Einfacher Ansatz: Thresholding
- Komplexer Ansatz: Optimierungsproblem auf einem gewichteten bipartiten Graphen

Klassifizierung von Schema Matchern [RB01]

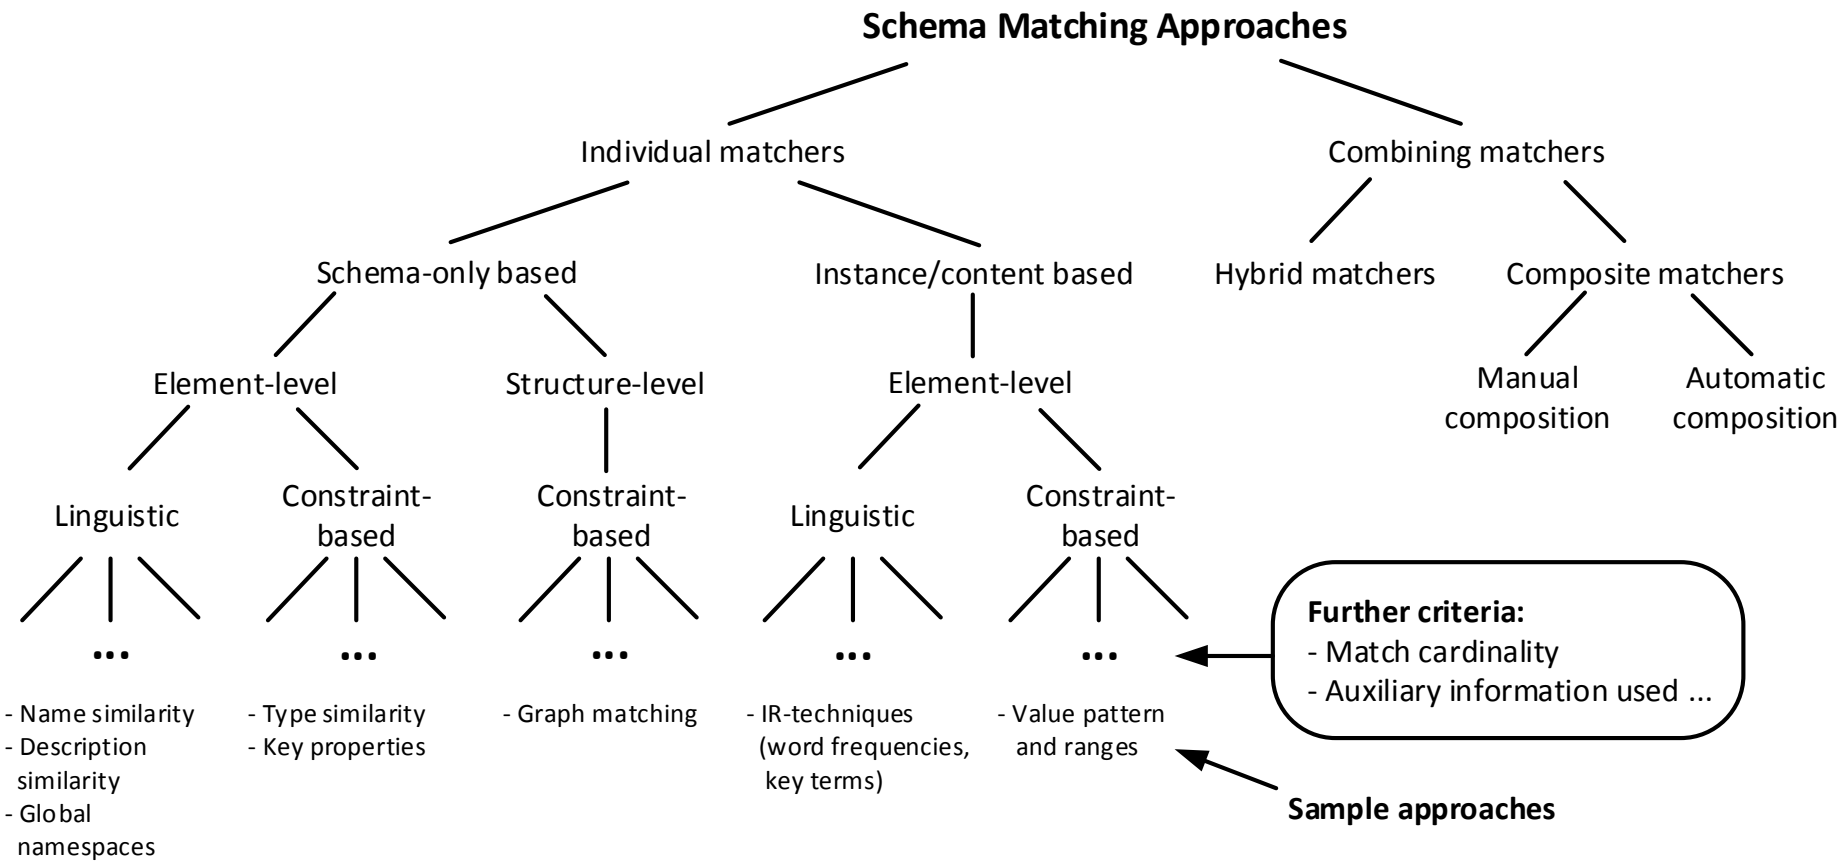

Schema Matching – Klassifikation

Schema Matching basierend auf

- Namen der Schemaelemente (*label-based*)
- Darunterliegende Daten (*instance-based*)
- Struktur des Schemas (*structure-based*)
- Mischformen

Schema Matching – Label-based

- Gegeben: Zwei Schemata mit Elementmengen $\mathcal{A}$ und $\mathcal{B}$
- Kernidee:
  - Bilde Kreuzprodukt aller Elemente aus $\mathcal{A}$ und $\mathcal{B}$
  - Für jedes Paar: vergleiche Ähnlichkeit bzgl. Elementnamen (Label) anhand Ähnlichkeitsmaß (z.B. *Edit distance* für Zeichenketten)
  - Ähnlichste Paare sind Matches
- Probleme:
  - Effizienz
  - Auswahl der besten Matches (globales Matching)
  - Synonyme und Homonyme werden nicht erkannt

Schema Matching – Label-based

Erhöhung der Matching Qualität durch Normalisierung

- Zerlegung der Label nach bestimmten Trennzeichen wie Großbuchstaben, Nummern oder speziellen Symbolen
  Beispiel: *saleLocID* wird zerlegt in *sale*, *Loc* und *ID*
- Ausschreibung von Abkürzungen oder Akronymen
  Beispiel: *Loc* wird erweitert zu *Location*
- Entfernen von Artikeln, Präpositionen und Konjunktionen
- Transformation von Wörtern in ihre Stammformen

Label-based (Beispiel)

DVD-Vendor
Movies(id, title, year)
Products(mid, releaseDate, releaseCompany, basePrice, rating, saleLocID)
Locations(lid, name, taxRate)

AGGREGATOR
Items(name, releaseInfo, classification, price)

label-based matcher
name = ⟨ name: 1, title: 0.2 ⟩
releaseInfo = ⟨ releaseDate: 0.5, releaseCompany: 0.5 ⟩
price = ⟨ basePrice: 0.8 ⟩

Schema Matching – Instance-based

- Gegeben: Zwei Schemata mit Attributmengen $\mathcal{A}$ und $\mathcal{B}$ (jeweils mit darunterliegenden Daten)
- Kernidee:
  - Für jedes Attribut: extrahiere interessante Eigenschaften der Daten (z.B. Buchstabenverteilung, Länge)
  - Bilde Kreuzprodukt aller Attribute aus $\mathcal{A}$ und $\mathcal{B}$
  - Für jedes Paar: vergleiche Ähnlichkeit bzgl. der Eigenschaften
- Probleme:
  - Auswahl der Eigenschaften
  - Menge der Daten: Sampling?
  - Vergleichsmethode (z.B. Naive Bayes)
  - Gewichtung (Maschinelles Lernen)

Instance-based Verfahren

- Konventionelle Lösung: Vertikal
  - Vergleich von Spalten
  - *Attribute classification*
  - Beispiel: [NHT+02]
- Andere Lösung: Horizontal
  - Vergleich von Tupeln
  - *Duplicate detection* (trotz fehlender Attribut-Korrespondenzen)
  - Attribut-Matching auf Basis der Duplikate
  - Beispiel: [BN05]

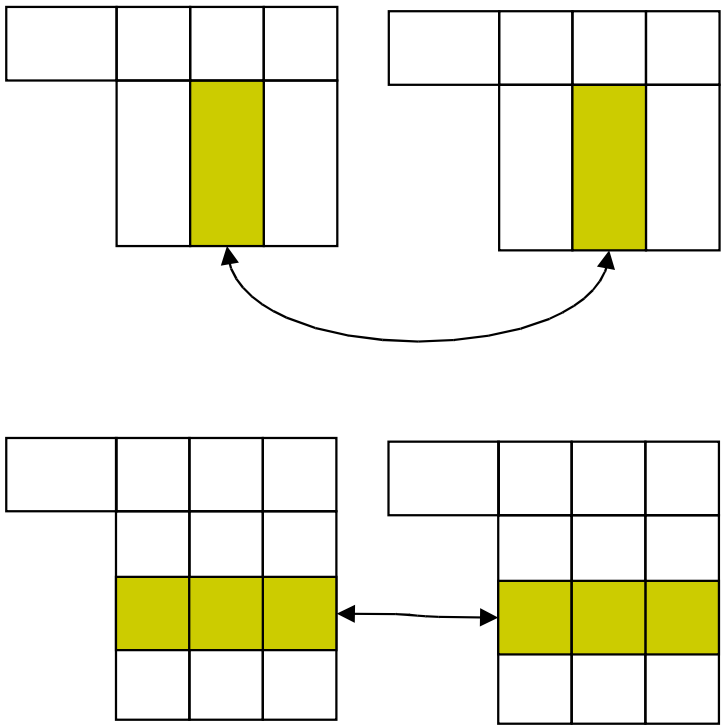

Instance-based (Beispiel - Vertikal)

SCHEMA S

current-showing	**address**	**phone**
Lord of the Rings	Madison WI	(608) 695 2311
	Mountain View CA	(650) 277 1358

SCHEMA T

name	**location**	**phone**
...	Milwaukee WI	...
	Palo Alto CA	
	Philadelphia PA	

- Korrespondenz zwischen *address* und *location* wird anhand der vorhandenen Attributwerte gefunden

Instance-based (Beispiel - Horizontal) [BN05]

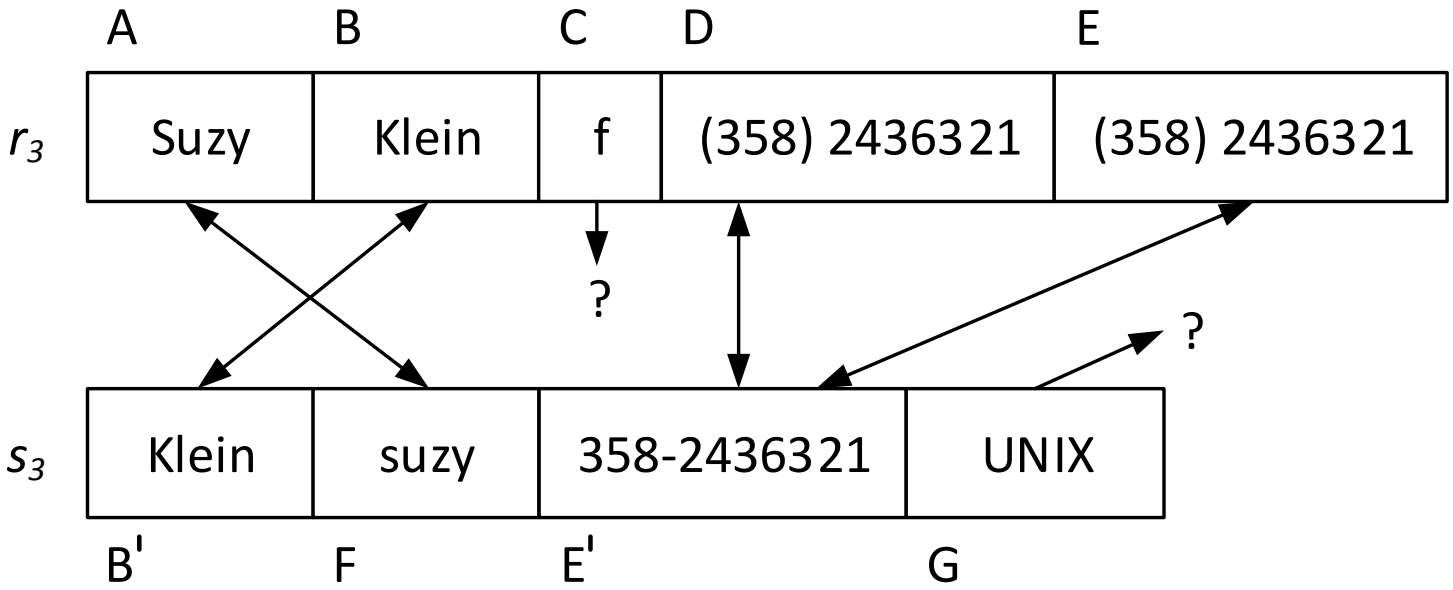

- Haben die Attribute C und G keine Korrespondenz?
- Korrespondiert Attribut E' mit D oder E?

Instance-based (Vertikale Verfahren)

- Recognizers
  - verwenden Kontextinformationen
- Overlap Matcher
  - bestimmen den Anteil gemeinsamer Datenwerte
- Klassifizierer
  - lernende Verfahren

Recognizer

- Benutzung von Wörterbüchern oder Regeln um Datenwerte bestimmter Attribute zu erkennen
- Attribute für die Recognizer nützlich sind:
  - Namen von Städten, Ländern oder Staaten
  - Personennamen
  - Farben, Bewertungen (e.g., $-$, $\circ$, $+$, etc.), Telefonnummern, Postleitzahlen
  - Genome, Proteine
- Vergleich eines Schemaelementes mit einer Menge an Konzepten

$\Rightarrow$ Instanzdaten des globalen Schemas nicht erforderlich

Overlap Matcher

- Überlappung von Elementinstanzen bestimmen
- Nutzung mengenbasierter Ähnlichkeitsmaße (e.g. Jaccard)
- hauptsächlich nützlich für Attribute mit endlichen Wertebereichen
- Problem: Die globale Sicht ist virtuell (keine Instanz vorhanden)

Klassifizierer

- Idee: Lerne binären Klassifizierer auf Elemente eines Schemas und nutze sie um die Elemente eines anderen Schemas zu klassifizieren
- Verschiedene Klassifizierungsmehtoden geeignet: Naive Bayes, Entscheidungsbäume oder Support-Vector Machines
- Trainingsdaten
  - Positive Beispiele: Werte des betrachteten Elementes
  - Negative Beispiele: Werte von anderen Elementen

  pause
- Probleme
  - Alle negativen Beispiele den positiven zu unähnlich (Personennamen fÃ¼r Telefonnummern)

  $\Rightarrow$ Klassifizierer wird trivial

Klassifizierer

- Vergleich zweier Schemaelemente anhand der Klassifizierung des zweiten Elementes mit dem Klassifier des ersten Elementes
  - Berechnung eines normierten *Confidence*-Wertes per Elementinstanz
  - Aggregation aller *Confidence*-Werte als Ähnlichkeit der Elemente
- Unidirektional vs. bidirektional
- Alle Quellschemata werden gegen das globale Schema gematched

$\Rightarrow$ Wiederverwendbarkeit wird erhöht wenn Klassifizierer für das globale Schema gelernt werden

- Problem: Keine Instanz vorhanden

Klassifizierer (Beispiel)

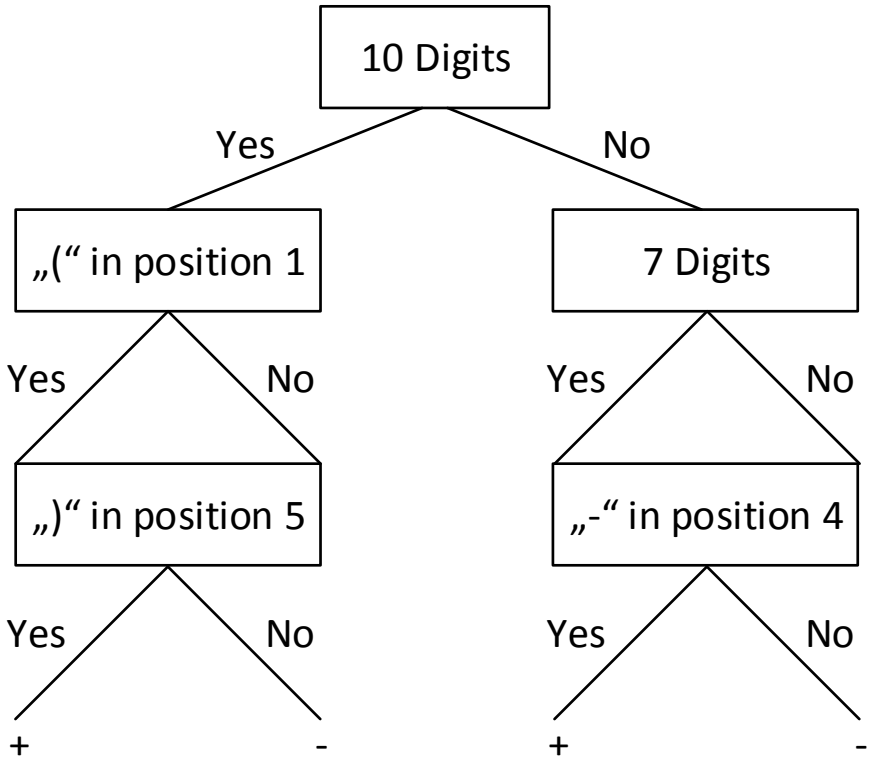

- Entscheidungsbaum für Telefonnummern
- Jeder Eingabewert wird klassifiziert als
  - Telefonnummer (+)
  - keine Telefonnummer (-)

Klassifizierer

- Overlap Matcher und Klassifizierer brauchen Instanzdaten
- Problem: Das globale Schema ist virtuell und hat keine Instanz
- Lösung: Man benutzt bereits vorhandene Mappings zu anderen Quellschemata um Trainingsdaten für das globale Schema zu gewinnen

$\Rightarrow$ Das System lernt aus vergangenen Matchingprozessen um die Qualität und Effizienz zukünftiger Matchingprozesse zu erhöhen

Schema Matching – Structure-based

- Gegeben: Zwei Schemata mit Attributmengen $\mathcal{A}$ und $\mathcal{B}$
- Kernidee:
  - Ausnutzen der (komplexen) Struktur der Schemata
  - Hierarchieebene
  - Elementtyp (Attribut, Relation, ...)
  - Nachbarschaftsbeziehungen

Beispiel: Similarity Flooding [MGMR02]

- Gegeben initiale Ähnlichkeit zwischen Schemaelementen (z.B. durch *edit distance* oder Instanzanalyse)
- Lasse Ähnlichkeiten abfärben auf die Nachbarn
  - Nachbarn sind durch Struktur definiert
  - Sind alle Nachbarn von x und y ähnlich zueinander, sind (vielleicht) auch x und y ein *Match*
- Analogie: Man flutet das Netzwerk der Ähnlichkeiten bis ein Gleichgewicht erreicht ist

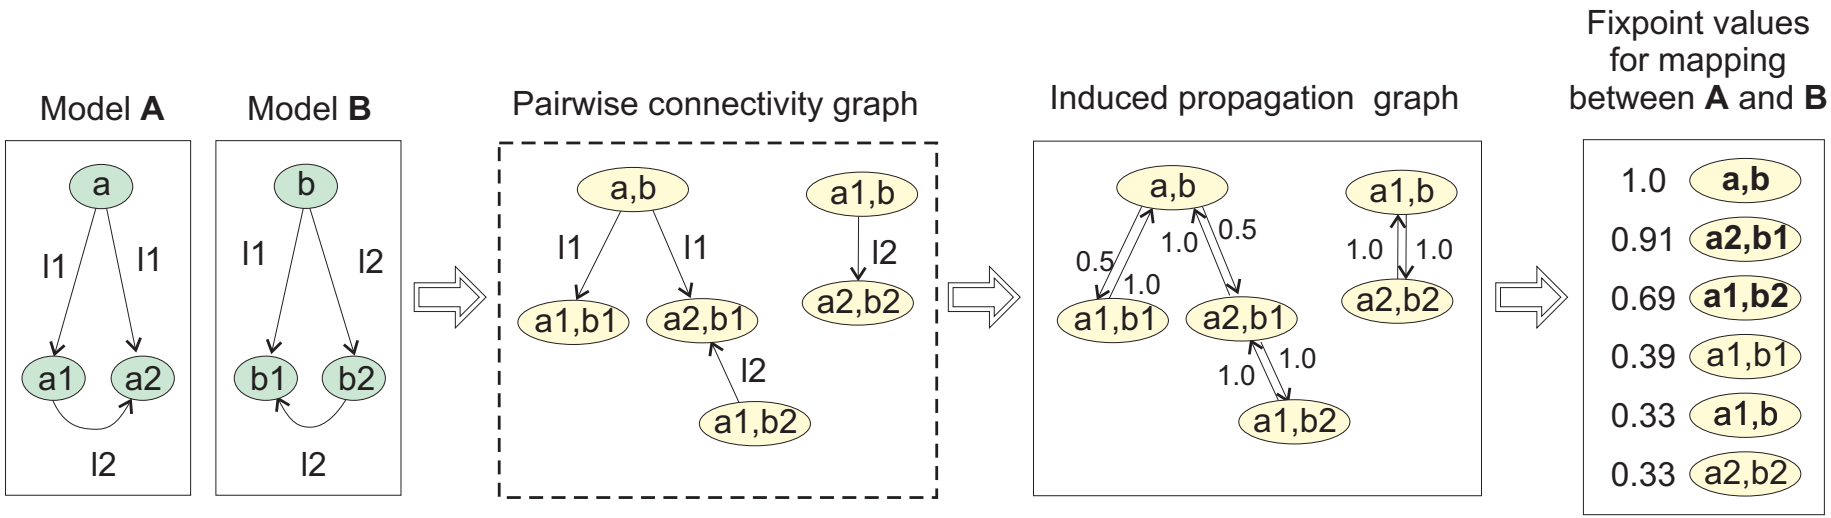

Anfrage-basierte Matcher

- Vergleich von Schemaelementen basierend auf der Art und Weise wie sie in Anfragen verwendet werden
- Erfordert Vergleich von semantisch ähnlichen Anfragen
- Problem: Welche Anfragen sind semantisch ähnlich?
- Auswahl basierend auf:
  - Kontextwissen wie z.B. Kenntnisse der Schnittstellen
  - Statistischen Mustern wie z.B. Häufigkeit oder Größe der Ergebnismenge
- Erfordert Zugriff auf Anfragen (und Anfragestatistiken) der einzelnen Quellen (Anfragen des globalen Schemas sind bekannt)

Anfrage-basierte Matcher (Beispiel 1)

Anfrage-basiertes Matching

```
SELECT Name, Alter, Ort                SELECT Fname, Lname, DoB, Residence
FROM   Person                          FROM   Person
WHERE  EMail = ...                     WHERE  EMail = ...
```

Indiz für Korrespondenz zwischen

- Name und {FName, LName}
- Alter und DoB
- Ort und Residence

Anfrage-basierte Matcher (Beispiel 1)

Anfrage-basiertes Matching

```
SELECT Name, Alter, Ort                SELECT Fname, Lname, DoB, Residence
FROM   Person                          FROM   Person
WHERE  EMail = ...                     WHERE  EMail = ...
```

Indiz für Korrespondenz zwischen

- Name und {FName, LName}
- Alter und DoB
- Ort und Residence

Anfrage-basierte Matcher (Beispiel 1)

Anfrage-basiertes Matching

```
SELECT Name, Alter, Ort                SELECT Fname, Lname, DoB, Residence
FROM   Person                          FROM   Person
WHERE  EMail = ...                     WHERE  EMail = ...
```

Indiz für Korrespondenz zwischen

- Name und {FName, LName}
- Alter und DoB
- Ort und Residence

Anfrage-basierte Matcher (Beispiel 2)

Anfrage-basiertes Matching

```
SELECT Phone                          SELECT Vorname, Nachname
FROM   Person                         FROM   Person
WHERE  Residence = 'Hamburg'          WHERE  Ort = 'Hamburg'
```

Indiz für Korrespondenz zwischen

- Residence und Ort

Anfrage-basierte Matcher (Beispiel 3)

Anfrage-basiertes Matching

```
SELECT Phone                          SELECT Phone
FROM   Person                         FROM   Person
WHERE  Firstname = 'Klaus'            WHERE  Name = 'Klaus Meier'
AND    Surname = 'Meier'
```

Indiz für Korrespondenz zwischen

- {Firstname, Surname} und Name

Anfrage-basierte Matcher (Beispiel 4)

Anfrage-basiertes Matching

```
SELECT f.Title, a2.Name                SELECT f.Title, a.Name
FROM   Film f, Act a1, Actor a2        FROM   Film f, Plays p, Actor a
WHERE  a1.Film = f.FID                 WHERE  p.FID = f.FID
AND    a1.Actor = a2.AID               AND    p.AID = a.AID
```

Annahme: FK zwischen den einzelnen Tabellen nicht existent
oder nicht bekannt

Indiz für Korrespondenz zwischen

- Act und Plays (Tabellen-Ebene)
- Act.Film und Plays.FID (Attribut-Ebene)
- Act.Actor und Plays.AID (Attribut-Ebene)

Anfrage-basierte Matcher (Beispiel 5)

Anfrage-basiertes Matching

```
SELECT Titel, Länge                SELECT Titel, Länge
FROM   Film                        FROM   Horrorfilm
WHERE  Genre = 'Horror'
```

Indiz für Korrespondenz zwischen

- {Film, Film.Genre='Horror'} und Horrorfilm

Kombinierung von Match Vorhersagen

realestate.com

listed-price	contact-name	contact-phone	office	comments
$250K	James Smith	(305) 729 0831	(305) 616 1822	Fantastic house
$320K	Mike Doan	(617) 253 1429	(617) 112 2315	Great location
.....	.....	.....	.....	.....

homes.com

sold-at	contact-agent	extra-info
$350K	(206) 634 9435	Beautiful yard
$230K	(617) 335 4243	Close to Seattle

- Label-based Matching: *contact-agent* matched entweder mit *contact-name* oder *contact-phone*
- Instance-based Matching: *contact-agent* matched entweder mit *contact-phone* oder *office*
- Beides: *contact-agent* matched mit *contact-phone*

Kombinierung von Match Vorhersagen

- Aggregation mehrer Ähnlichkeitsmatrizen
- Einfache Aggregationsmethoden
  - Durchschnitt: Wir vertrauen allen Matchern gleich
  - Maximum: Vertrauen in positive Signale einzelner Matcher
  - Minimum: Vertrauen in negative Signale einzelner Matcher
- Handgeschriebene Skripte
  - Manchmal gibt es Vorkenntnisse welche Matcher in welchen Domänen zuverlässig sind
  - Durch Skripte sind beliebige Kombinationen von Aggregationen und Kontextinformationen möglich
    Beispiel: Benutze Matcher x wenn es sich um einen Vergleich mit dem Attribut *Adresse* handelt
- Gewichtete Aggregation
  - Gewichte von Domänexperten spezifiziert
  - Lernverfahren um elementspezifischer Gewichte zu bestimmen

Match Selector

- Bildet die Ähnlichkeitsmatrix auf eine Menge an Korrespondenzen ab (sog. *Match Combination*)
- Einfache Methode: Wähle alle Elementpaare deren Ähnlichkeit größer θ ist
- Problem: Nicht konsistent, da ein Element von Schema $\mathcal{A}$ mit mehreren Elementen von Schema $\mathcal{B}$ gematched werden kann (keine 1:n Korrespondenz!)
- Bessere aber auch aufwendigere Verfahren: *Stable Marriage* und *Maximum Weighted Matching*
- Manchmal ist es sinnvoll mehrere Match Combinations auszugeben und dem Nutzer das Auflösen von verbleibenden Unsicherheiten überlässt

Stable Marriage

- Gegeben: n Frauen (Elemente in Schema $\mathcal{A}$) und m Männer (Elemente in Schema $\mathcal{B}$)
- Monogamie:
  Je eine Frau kann nur mit je einem Mann verheiratet sein (nur 1:1 Matches)
- Jede Frau hat eine Rangliste der Männer und umgekehrt.
  Beim Schema Matching:
  - Rangliste basiert auf den Ähnlichkeiten der Schemaelemente
  - Trotz symmetrischer Ähnlichkeitsmatrix, Ranglisten können sich stark unterscheiden
- Gesucht: Paarung (globales Matching), so dass niemals gilt:
  - f_1 heiratet m_1, f_2 heiratet m_2
  - aber f_1 bevorzugt m_2 und m_2 bevorzugt f_1 (instabile Paarung)

Stable Marriage

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 und 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)

Maximum Weighted Matching

- Alternative zu *Stable Marriage*
- Suche Matching mit maximalem Gewicht in bipartiten Graphen
  - Bipartit:
    - Knoten in zwei Klassen (Quelle & Ziel)
    - Kanten nur zwischen Knoten verschiedener Klassen (Korrespondenzen)
  - Maximiere Summe der einzelnen Gewichte/Ähnlichkeiten

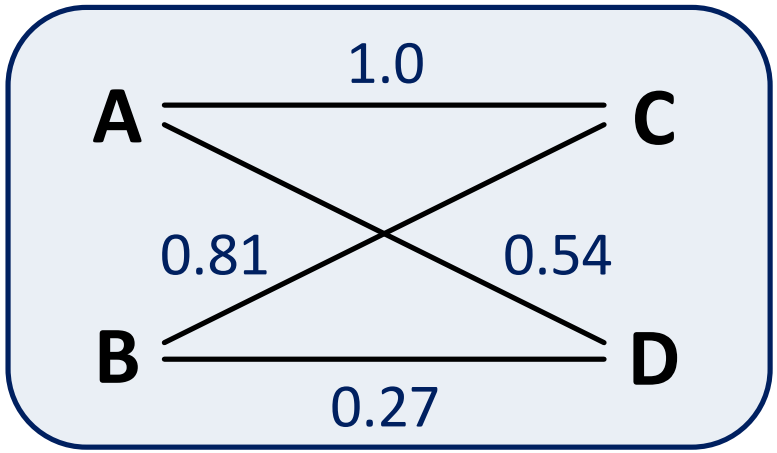

Maximum Weighted Matching (Wdh.)

Gegeben: Ein (gewichteter) Graph $G = (V, E, w)$

- Ein Matching M von G ist eine Menge an Kanten die sich keine Knoten teilen (die Kanten sind paarweise nicht adjazent)
- Ein Maximal Matching M von G ist ein Matching das nicht erweitert werden kann (d.h. das Hinzufügen einer weiteren Kante von G bedeutet, dass M kein Matching mehr ist)
- Ein Maximum Matching M von G ist ein Matching das (unter allen mgl. Matchings) die maximale Anzahl an Kanten besitzt
- Ein Maximum Weighted Matching M von G ist ein Matching bei dem die Gesamtsumme aller Kantengewichte maximal ist

Maximum Weighted Matching

Gegeben: Ein (gewichteter) Graph $G = (V, E, w)$

- Finden des Maximum Weighted Matching M von G ist ein Zuordnungsproblem
- bipartite Graphen: Hungarian algorithm (Komplexität $\mathcal{O}(V^2E)$ oder $\mathcal{O}(V^2 \log V + VE)$)
- generell: Edmonds' algorithm (Komplexität $\mathcal{O}(V^2E)$)

Anmerkungen:

- Das Maximum Weighted Matching soll nur Korrespondenzen mit großer Glaubwürdigkeit enthalten

$\Rightarrow$ Alle Korrespondenzen deren Glaubwürdigkeit kleiner als ein Schwellwert ist, bekommen die Glaubwürdigkeit 0
(in hybriden String Matching Verfahren ähnlich)

Einbinden von Integritätsbedingungen

- Domänenwissen kann helfen die Glaubhaftigkeit einiger Korrespondenzen zu erhöhen/verringern
- Modellierung von Domänenwissen mit Hilfe von Integritätsbedingungen
- Glaubhaftigkeit einer Korrespondenz erhöht sich, wenn sie viele/alle Integritätsbedingungen erfüllt
- Glaubhaftigkeit einer Korrespondenz verringert sich, wenn sie einige Integritätsbedingungen verletzt
- Ändern der Glaubhaftigkeiten von Korrespondenzen durch Modifikation der Ähnlichkeitsmatrix

Beispiel: Modellierung von Domänenwissen [DHI12]

average-combiner
name = ⟨ name: 0.6, title: 0.5 ⟩
releaseInfo = ⟨ releaseDate: 0.6, releaseCompany: 0.25 ⟩
classification = ⟨ rating: 0.3 ⟩
price = ⟨ basePrice: 0.5 ⟩

- Domänenwissen: die meisten Filmtitel (AGGREGATOR.name) bestehen aus vier Wörtern oder mehr

⇒ Bedingung: „*Ein Attribut A kann AGGREGATOR.name nur matchen, wenn in einem zufällig gewählten Sample von 100 Datenwerten mindestens 10 Werte vier Wörter oder mehr besitzen*“

Arten von Integritätsbedingungen

- Zwei Arten von Integritätsbedingungen
- Harte Bedingungen
  - müssen erfüllt sein
  - keine der ausgewählten Korrespondenzen darf sie verletzten
- Weiche Bedingungen
  - sind eher heuristischer Natur
    (können unter Umständen verletzt werden)
  - Verletzung dieser Bedingungen soll minimiert werden
- Jede Bedingung wird mit einem Kostenwert versehen
  - für harte Bedingungen sind die Kosten unendlich
  - für weiche Bedingungen kann irgendein positiver Kostenwert gewählt werden

Beispiel: Integritätsbedingungen [DHI12]

BOOK-VENDOR
Books(ISBN, publisher, pubCountry, title, review)
Inventory(ISBN, quantity, location)

DISTRIBUTOR
Items(code, name, brand, origin, desc)
InStore(code, availQuant)

	Constraints	Costs
c_1	If A = Items.code, then A is a key	∞
c_2	If A = Items.desc, then any random sample of 100 data instances of A must have an average length of at least 20 words	1.5

Korrespondenz übergreifende Bedingungen

- Problem: Integritätsbedingungen betreffen oft Kombinationen von Korrespondenzen (anstatt einzelne)

$\Rightarrow$ Modellierung einer reduzierten Glaubwürdigkeit in der Ähnlichkeitsmatrix nicht möglich

- Daher Auswahl der besten Match Combination die alle (harten) Bedingungen erfüllt bzw. die geringsten Kosten hat ($\Rightarrow$ Anwendung nach oder kombiniert mit Match Selector)
- Frage: Wie bestimmt man die Güte einer Match Combination?
- Einfache Lösung: Annahme das alle Confidence-Werte unabhängig voneinander bestimmt wurden

$\Rightarrow$ Multiplizieren der Confidence-Werte aller Korrespondenzen in der Match Combination

Beispiel: Güte von Match Combinations [DHI12]

average-combiner
name = ⟨ name: 0.6, title: 0.5 ⟩
releaseInfo = ⟨ releaseDate: 0.6, releaseCompany: 0.25 ⟩
classification = ⟨ rating: 0.3 ⟩
price = ⟨ basePrice: 0.5 ⟩

- Es gibt vier Match Combinations $M_1 - M_4$
  Beispiel: $M_1 = \{\text{name} = \text{name}, \text{releaseInfo} = \text{releaseDate}, \text{classification} = \text{rating}, \text{price} = \text{basePrice}\}$
- Für jede Match Combination M_i berechnen wird die Güte indem wir die individuellen Confidence-Werte multiplizieren
  Beispiel: $score(M_1) = 0.6 \times 0.6 \times 0.3 \times 0.5$

Beispiel: Korrespondenz übergreifende Bedingung [DHI12]

BOOK-VENDOR
Books(ISBN, publisher, pubCountry, title, review)
Inventory(ISBN, quantity, location)

DISTRIBUTOR
Items(code, name, brand, origin, desc)
InStore(code, availQuant)

	Constraints	Costs
c_1	If A = Items.code, then A is a key	∞
c_2	If A = Items.desc, then any random sample of 100 data instances of A must have an average length of at least 20 words	1.5
c_3	If $A_1 = B_1, A_2 = B_2$, B_2 is next to B_1 in the schema, but A_2 is not next to A_1, then there is no A* next to A_1 such that $\lvert sim(A^*,B_2) - sim(A_2,B_2)\rvert \leq t$ for a small pre-specified t	2
c_4	If more than half of the attributes of Table U match those of Table V, then U = V	1

Einbinden von Integritätsbedingungen

- Der Enforcer muss für jede Match Combination entscheiden können ob diese die gegebenen Bedingungen erfüllt
- Problem: Auch wenn eine Bedingung durch die gegebene Instanz nicht verletzt ist, muss nicht gelten, dass die Bedingung nicht durch eine zukünftige Instanz verletzt wird
- Beispiel: Wenn alle Werte eines Attributes verschieden sind, muss dies nicht bedeuten, dass dieses Attribut ein Schlüsselkandidat ist
- Gegebene Quellinstanzen reichen meistens aber aus um schnell Verletzungen von Integritätsbedingungen zu entdecken

Einbinden von Integritätsbedingungen

- Naiver Ansatz:
  - Sortiere alle Match Combinations nach ihrer Güte
  - Iteriere über die sortierte Liste bis eine Match Combination alle Bedingungen erfüllt
- In der Praxis meist zu ineffizient
  - Auswertung von Bedingungen kann komplex sein
  - Anzahl an Match Combinations ist meist sehr groß
    ($\Rightarrow$ Die Güte kann nicht für jede berechnet werden)
- Zudem: Keine Kosten von schwachen Bedingungen berücksichigt
- Effizientere Methoden benötigt (z.B. A*-Suche)

A*-Suche

- Die A*-Suche lässt sich als wachsender Baum visualisieren
  - Wurzel = Startzustand
  - einige Blätter sind Zielzustand
  - Jeder Pfad ist mit Kosten versehen
- Die A*-Suche findet ausgehend vom Startzustand den Endzustand mit den minimalen Kosten (garantiert)
- Bestensuche: Solange der aktuell kostengünstigste Zustand kein Endzustand ist:
  - Wähle den aktuell kostengünstigste Zustand
  - Expandiere den gewählten Zustand in eine Menge neuer Zustände
- Kosten eines Zustandes Z = Kosten des Pfades von Startzustand zu Z + lower bound für die Kosten des günstigen Pfades von Z zu einem Zielzustand

Beispiel: A*-Suche

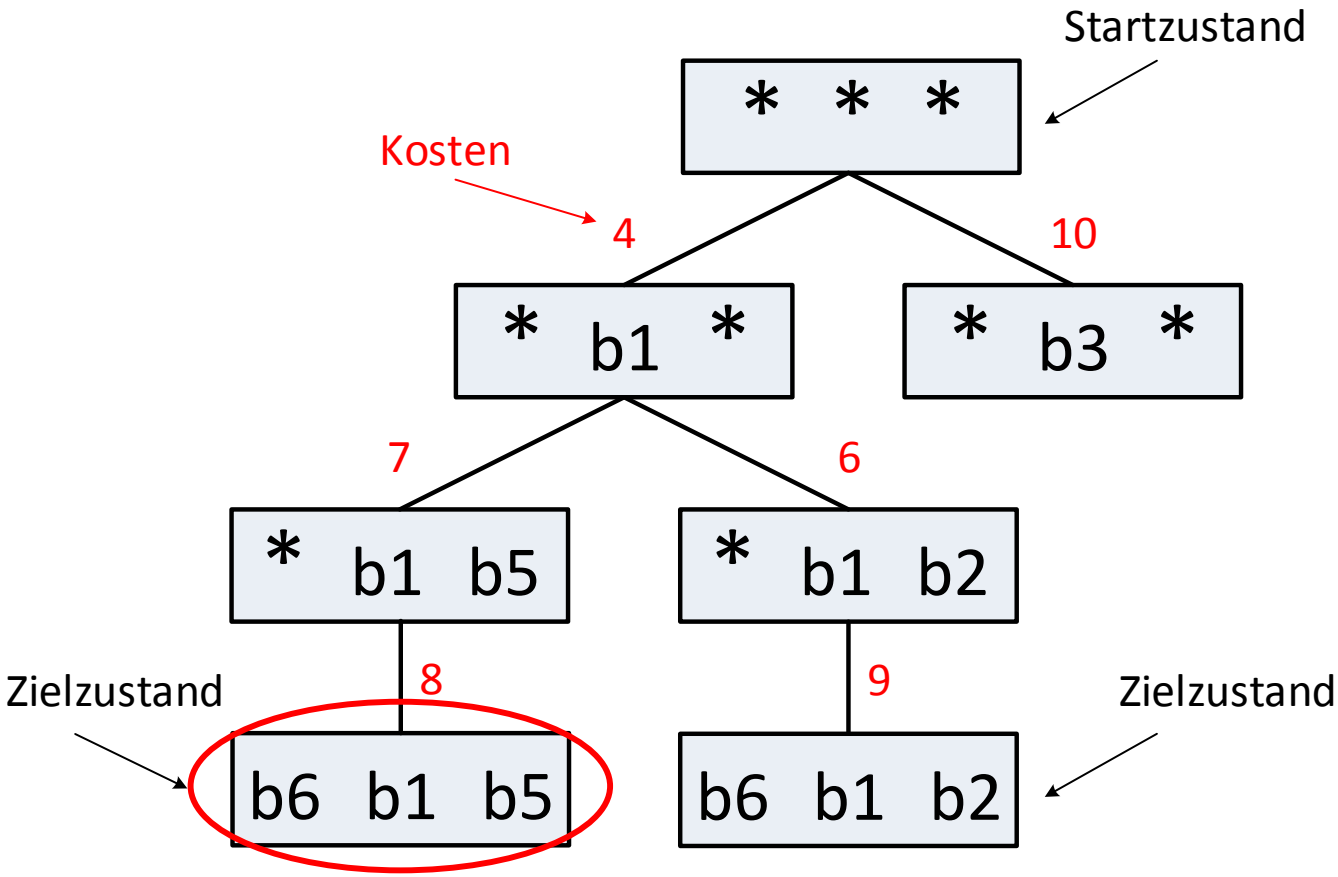

A*-Suche bzgl. Integritätsbedingungen

- Ziel: A*-Suche um zwei Schemata $\mathcal{A}$ und $\mathcal{B}$ zu matchen
  - $\mathcal{A}$ hat Elemente $\{A_1, \ldots, A_n\}$
  - $\mathcal{B}$ hat Elemente $\{B_1, \ldots, B_m\}$
- Jeder Zustand entspricht einem n-tuple
  (eine Position pro Element in $\mathcal{A}$)
- Wert an Position i ist entweder
  - eine Korrespondenz für A_i (also ein Element in $\mathcal{B}$)
  - einen Nullwert '$\perp$'
    (es gibt zu A_i kein korrespondierendes Element in $\mathcal{B}$)
  - oder eine Wildcard '*'
    (die Korrespondenz ist noch nicht spezifiziert)

A*-Suche bzgl. Integritätsbedingungen

$\Rightarrow$ Jeder Zustand repräsentiert eine Menge an Match Combinations

- Der Startzustand enthält nur Wildcards, d.h. $(*, *, \ldots, *)$ (entspricht allen möglichen Match Combinations)
- Ein Zielzustand enthält keine Wildcards (entspricht einer einzigen Match Combination)
- Expansion eines Zustandes
  - Wähle eine Wildcard an Position i
  - Erzeuge einen Zustand für jede mögliche Korrespondenz von A_i
- Auswahl der zu expandierenden Wildcard beeinflusst Effizienz

A*-Suche bzgl. Integritätsbedingungen

- Grobes Ziel: Beste Match Combination mit den geringsten (durch verletzte Bedingungen verursachten) Kosten
- Problem: A*-Suche berücksichtigt nur Kosten und keine Güte
- Die von verletzten Bedingungen verursachten Kosten spiegeln allerdings auch eine Art von Güte wieder

$\Rightarrow$ Kosten eines Pfades: Kombination von Güte des erreichten Zustandes und Kosten verursacht durch die Bedingungen die durch den Zustand verletzt werden (Wildcards werden ignoriert)

Schema Matching – Weitere Anwendungen

- Herkömmlich: Korrespondenzen finden
- Schlüssel - Fremdschlüssel Beziehungen finden
  (ähnliche Attribute innerhalb eines Schemas sind gute Kandidaten)
- Höher-stufige Korrespondenzen finden
  (Ähnlichkeiten von Tabellen durch Aggregation der Matches ihrer Attribute)

n:m Korrespondenzen

- Bisher nur 1:1 Korrespondenzen
- Schemata sind aber oft so heterogen, dass n:m Korrespondenzen notwendig sind
- Beispiel 1:

SOURCE
Books(title, basePrice, taxRate, quantity, authorFirstName, authorLastName)

TARGET
Items(title, price, inventory, author, genre)

n:m Korrespondenzen:

- author = concat(authorFirstName, authorLastName)
- price = basePrice $\times$ (1 + taxRate)

n:m Korrespondenzen (Beispiel)

- Beispiel 2:

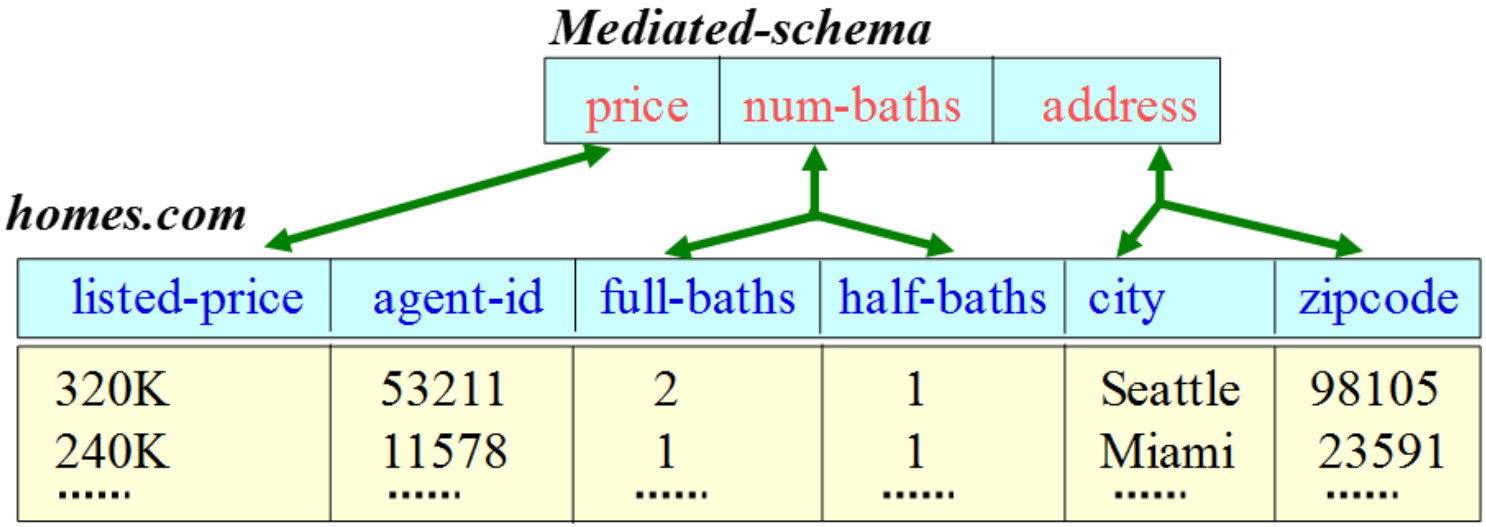

n:m Korrespondenzen:

- num-baths = full-baths + half-baths
- address = concat(city, zipcode)

n:m Korrespondenzen

- Problem: Man kann nicht alle möglichen Kombinationen testen (evtl. unendliche viele)
- Verwendung spezieller *Searcher*, die für bestimmte Datentypen und Domänen konzipiert sind
  - Text searcher: Konkatenationen von Elementen
  - Numeric searcher: Arithmetische Ausdrücke, Verwendung von häufig auftretenden Konstanten (z.B. zur Währungsumrechnung)
  - Date searcher: Kombinationen von Monat/Jahr/Tag
- Testen von Kombinationen speziell mit Instanzbasierten Matchern sinnvoll
- A*-Suche: Auswahl einer möglichen Korrespondenz für disjunkte Elementmengen $\mathcal{A}' \subseteq \mathcal{A}$ anstatt eines einzelnen Elementes von $\mathcal{B}$ pro Element in $\mathcal{A}$

Searcher (Beispiel)

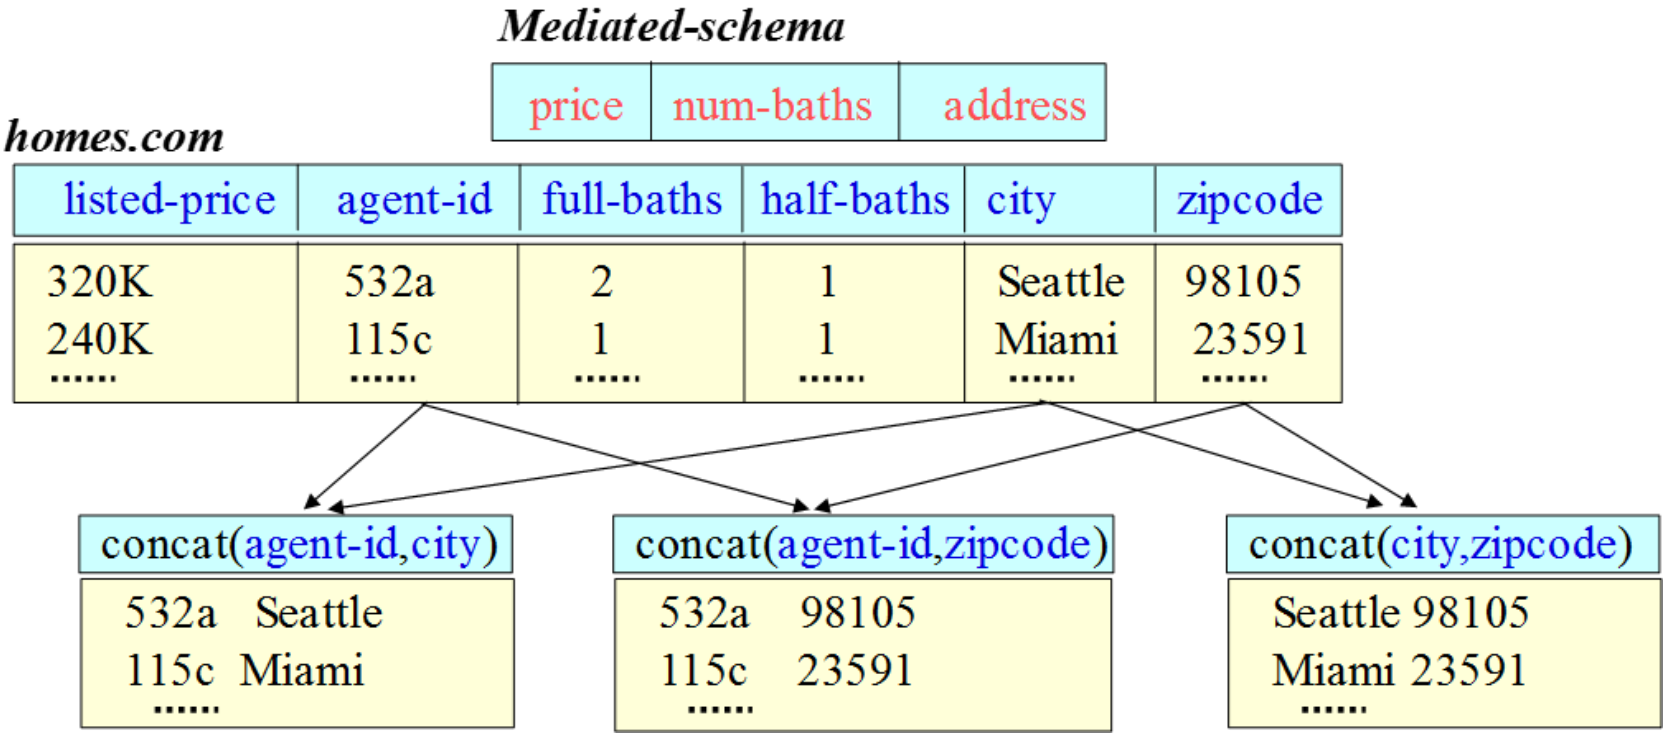

- Beste Match-Kandidaten für das Attribute *address*:
  - (agent-id,0.7)
  - (concat(agent-id, city),0.75)
  - (concat(city, zipcode),0.9)

Searcher

Searcher besteht aus drei Komponenten

- Suchstrategie: Bestimmt welche Elemente mit welchen Funktionen verknüpft werden und nach welchem Konzept die Suche verläuft (genetische Ansätze denkbar)
- Evaluation: Berechnung einer Ähnlichkeit (wie bisher) aber Searcher können bestimmte Matcher diktieren
- Termination: Stoppkriterium um die (wohlmöglich sonst endlose) Suche zu beenden

  Beispiel: Stoppe die Suche wenn die bis dato maximale gefundene Ähnlichkeit bei den letzten 100 getesteten Kombinationen nicht mehr gestiegen ist

Modifizierte Matching Architektur

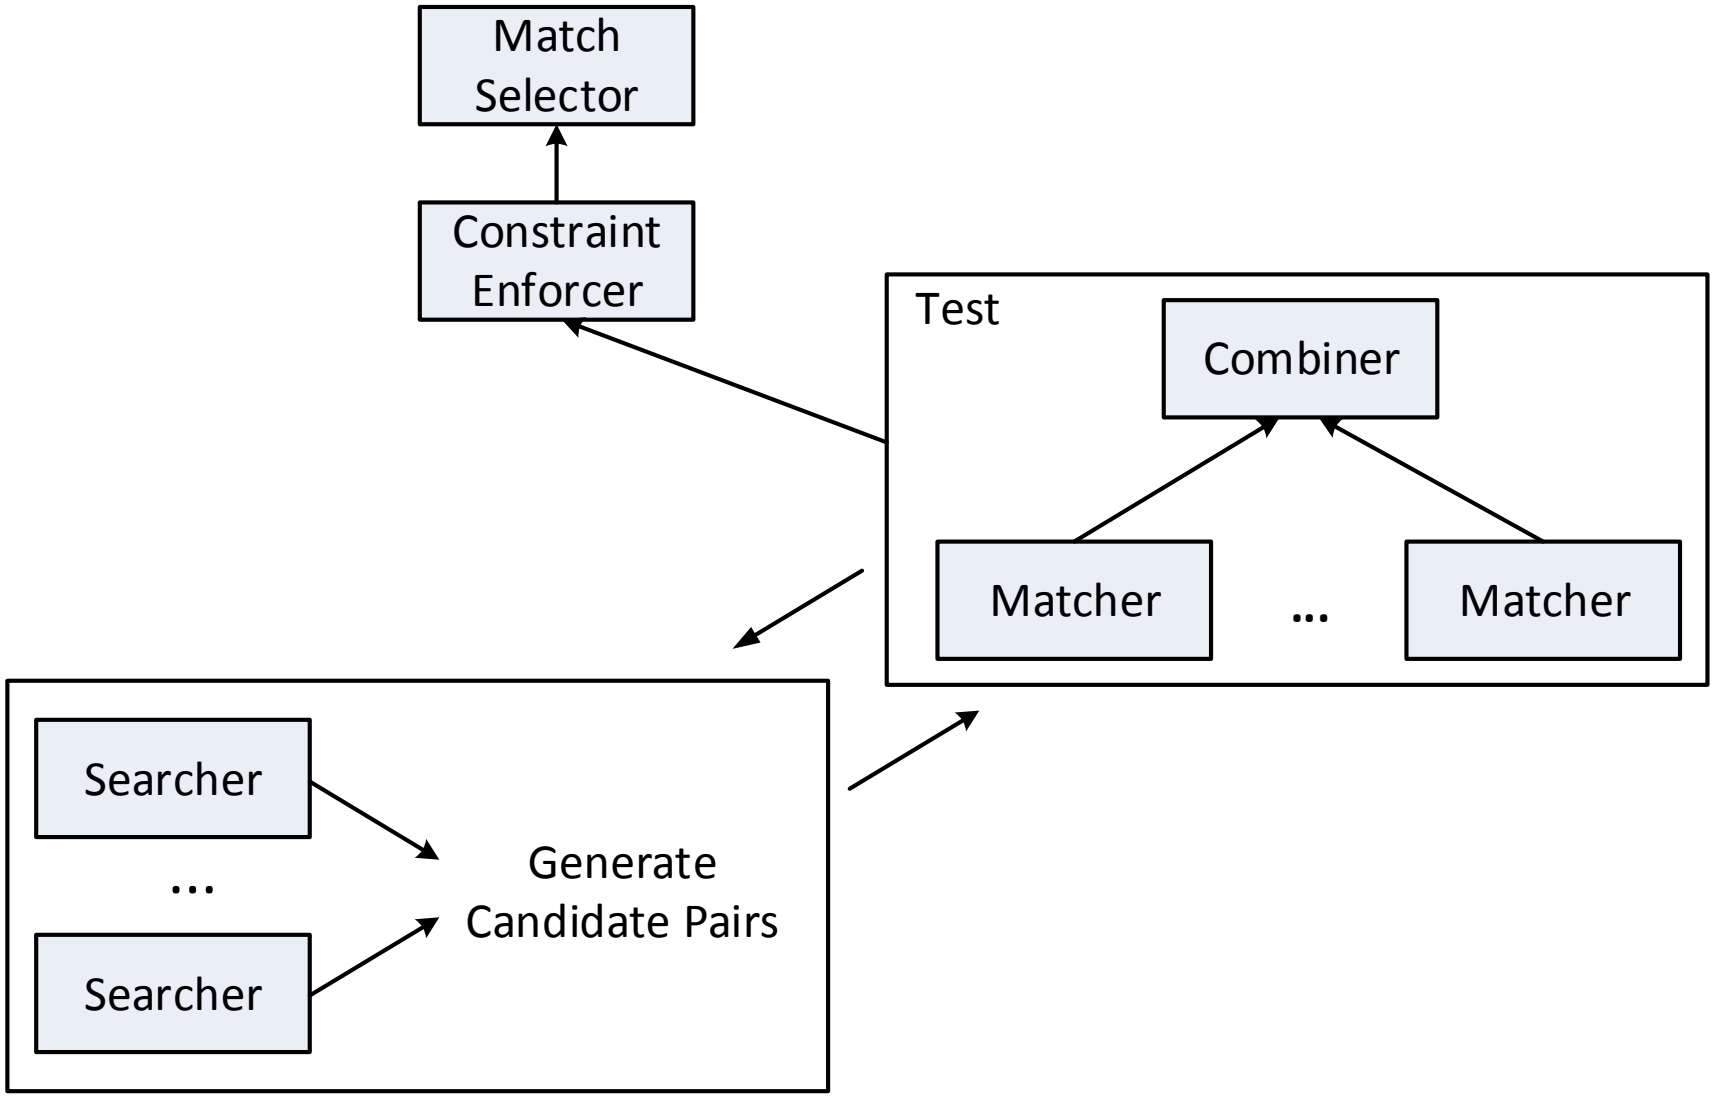

Zusammenfassung Schema Matching

- Schema Matching basierend auf
  - Namen der Schemaelemente (*label-based*)
  - Darunterliegende Daten (*instance-based*)
  - Struktur des Schemas (*structure-based*)
- Kombination von verschiedenen Matching Ergebnissen
- Einbinden von Integritätsbedingung
- Auswahl einer finalen Match Combination
- Suche nach n:m Korrespondenzen

Literatur I

[BCH+05] Angela Bonifati, Qing (Elaine) Chang, Terence Ho, Laks V.S. Lakshmanan, and Rachel Pottinger.
HePToX: Marrying XML and heterogeneity in your P2P databases.
In *Proc. of the Int. Conf. on Very Large Databases (VLDB)*, 2005.
Demo paper.

[BN05] Alexander Bilke and Felix Naumann.
Schema matching using duplicates.
In *Proc. of the Int. Conf. on Data Engineering (ICDE)*, 2005.

[DHI12] Anhai Doan, Alon Halevy, and Zachary Ives.
Principles of Data Integration.
Morgan Kaufmann, 2012.

[MMR02] Sergey Melnik, Hector Garcia-Molina, and Erhard Rahm.
Similarity Flooding: A versatile graph matching algorithm and its application to schema matching.
In *Proc. of the Int. Conf. on Data Engineering (ICDE)*, 2002.

Literatur II

[NHT+02] Felix Naumann, Ching-Tien Ho, Xuqing Tian, Laura Haas, and Nimrod Megiddo.
Attribute classification using feature analysis.
In *Proc. of the Int. Conf. on Data Engineering (ICDE)*, 2002.

[RB01] E. Rahm and P.A. Bernstein.
survey of approaches to automatic schema matching.
The VLDB Journal, 10(4):334-350, 2001.