

Instanz-basiertes Matching mit COMA++


Sabine Maßmann

Zingst, 2.Juli 2008



Einleitung

- Situation: Austausch von Daten zwischen verschiedenen Datenquellen mit unterschiedlichen Schemata in z.B. Forschung und B2B
- Schema Matching:
 - Identifizierung von Korrespondenzen zwischen einem Ausgangsschema und einem Zielschema
 - Erster Schritt zur Datenintegration und –transformation




Übersicht

- Einleitung
- Matching mit COMA++
- Erweiterung zum Instanz-basierten Matching
- Bisherige Evaluation:
 - OAEI
 - Webverzeichnisse
- Produktkataloge
 - Aktueller Stand
 - Nächste Schritte

COMA / COMA++

- **COMA** (*VLDB 2002 –Do und Rahm*)
 - Flexible Kombination von Matchalgorithmen (composite approach)
 - Unterstützung von relationalen Schemata
 - Wiederverwendung von vorherigen Matchergebnissen
 - Umfassende Evaluation
- **COMA++** (*SIGMOD 2005 – Aumüller, Do, Maßmann und Rahm*)
 - Generisches Datenmodell
 - GUI
 - Zusätzliche Unterstützung von XSD und OWL
 - Viele vordefinierte Matcher und flexible Konstruktion von neuen bzw. Änderung von vordefinierten Matchern
 - Strategien zum Umgang von großen Schemata und zur Wiederverwendung von bereits erstellten Mappings
 - Auch hier: umfassende Evaluation

Matchprozess bei COMA++




Motivation

- Herausforderungen beim (semi-) automatischen Matching
 - Heterogenitätsprobleme: terminologisch und konzeptuell
 - Redundanz
- Verwendung von Metadaten-basiertem Matching ist erfolgreich, hat aber Probleme im Umgang mit unverständlichen Namen, unbekanntem Synonymen und verschiedenen Sprachen
 - **als Ergänzung** (*Erweiterung von COMA++*) :
Verwendung von Instanzdaten für das Matching


Erweiterung für Instanz-basiertes Matching

- Import der Instanzdaten
- Erweiterte Schemarepräsentation: jedes Element kann zusätzlich zu bisherigen Daten wie Namen, Datentyp, etc. Instanzdaten beinhalten
- Import-Parser
 - Umgang mit unterschiedlichen Instanzquellen
 - Instanzdaten werden nach dem Parsen der generischen Schemarepräsentation zugewiesen




Constraint-basiertes Matching

- Constraints
 - Beschreibung von Charakteristiken oder Mustern
 - Zuweisung zu Schemaelementen
- Constraint-Gruppen:
 - **Allgemeine Constraints:** können für jede Instanz bestimmt werden
Beispiel: durchschnittliche Länge und verwendete Zeichen (Buchstaben, Zahlen, Sonderzeichen)
 - **Numerische Constraints:** Bestimmung, ob eine Instanz eine Zahl ist und welche Art
Beispiel: positiv oder negativ, Integer oder Fließkommazahl
 - **Pattern Constraints:** Untersuchung, ob alle Instanzen eines Elementes einem bestimmten Muster entsprechen
Beispiel: Email und URL
- Ähnlich dem Matching von Datentypen – mit dem Wissen auf Instanzdaten basierend



Content-basiertes Matching

- Zur Bestimmung der Ähnlichkeit: Matching der Instanzwerte selber
- Ermittelt die Ähnlichkeit zweier Elemente durch:
 1. Ausführung eines paarweisen Vergleichs der Instanzwerte unter der Verwendung einer Ähnlichkeitsfunktion
Ergebnis: eine Ähnlichkeitsmatrix in der jeweils eine Dimension, die Instanzen eines Elementes repräsentiert
 2. Vereinigung der Matrix zu einem Wert (Aggregation)
Ergebnis : Ähnlichkeit der Instanzmengen und somit der Elemente
- COMA++ unterstützt (neben Gleichheit) viele Ähnlichkeitsfunktionen, die auf Zeichenketten basieren
Beispiel: Trigram, Edit Distance, Soundex



Pro & Kontra

Constraint-basiertes Matching

- *Pro*: bei großen Instanzmengen nur geringer Aufwand
- *Kontra*: nicht geeignet für Fälle, die aus vielen Elementen mit “gemischten” Zeichenketten bestehen

Content-basiertes Matching

- *Pro*: Geeignet für Fälle, in denen Element-Instanzen gleich oder sehr ähnlich sind
Beispiel: Straßennamen → “Arthur-Straße” vs. “Arthur-Str.”
- *Kontra*: hoher Aufwand → $n \times m$ Vergleiche

Evaluation 1: OAEI-Benchmark

- OAEI Contest 2006 (<http://oaei.ontologymatching.org>) beinhaltet einen Benchmark
 - 51 Matchaufgaben
 - Eine Referenzontologie, die mit modifizierten Versionen gematcht werden muss
 - Unterschiedliche Modifikationen: Weggelassene Kommentare, flache Hierarchien, Namen wurden durch Zufallszeichenketten ersetzt,...
 - Für alle Aufgaben muss dieselbe Strategie und Konfiguration verwendet werden
- Beschränkung auf Ontologien mit mindestens einer Instanz
→ 39 Matchaufgaben mit 2966 Korrespondenzen in ihren Referenzalignments
- Evaluierung der Instanz-basierten Matcher alleine und mit Anwendung einer Propagation (nicht hier diskutiert)

1088 von 2966 Korrespondenzen sind zwischen 2 Elementen mit Instanzen → maximal möglicher Recall für Instanz-basiertes Matching **0.367**

Algorithmus	Precision	Recall	F-Measure
Content	0.997	0.353	0.521
Constraint	0.424	0.075	0.128

Viele Instanzen sind Zeichenketten und daher lassen sich mit Constraints nur wenige Instanz-Korrespondenzen identifizieren

Evaluation 2: Webverzeichnisse

- Webverzeichnisse, z.B. Dmoz
 - Semantische Kategorisierung von Websites
 - Verwendung: Auffinden relevanter Websites zu einem bestimmten Interessensgebiet

 open directory project

Metadaten

Top: Shopping: Clothing: Swimwear (181)


- Children's (15)
 - Men's (11)
 - Women's (104)
-

Instanzen

- AirTanBeachStore, Inc. - Offers bikinis, swimsuit, dresses and men's apparel. Also provides lingerie and accessories.
- Aloha Apparel - Board shorts and swimwear for men, women, teens, and kids.
- Avalon USA - Sexy swimwear for women.
- The Beachwear Network - Selection of beachwear.
- Berrydog Bikinis - Designer of bikinis and one piece swimsuits for women. Includes photos.
- Bikini Wholesale - Swimwear and bikinis. Worldwide shipping.
- Brigitewear - Sexy designer swimwear for man and woman specializing in thong, sheer, topless and G-string swimsuits.


Motivation zum Matching von Webverzeichnissen

- Viele verschiedene Webverzeichnisse, e.g. Dmoz and Yahoo
- Äquivalenzmappings können genutzt werden zur:
 - Informationsintegration der verschiedenen Verzeichnisse
 - Verbesserung von Anfrageergebnissen
 - Generierung von Website-Empfehlungen



Instanzen der Webverzeichnisse

- Instanzen sind Blättern und inneren Kategorien zugeordnet
- Verwendung von 3 Attributen: URL, Name, Beschreibung (Description)



- Instanz-basiertes Matching
 - 3 Instanzmengen: URL, Name, Beschreibung
 - Namen- und Beschreibungs-basiertes Matching :
 - Namen von Websites sind viel kürzer als Beschreibungen und beinhalten zum Großteil zusammengesetzte Worte und Personennamen
 - Vorverarbeitung, z.B. Entfernung einzelner Zeichen und Sonderzeichen
 - Ähnlichkeitsberechnung unter Verwendung von TFIDF (Gewichtung)

Abspeicherung der Instanzen in Repository

- Jedes Schema/Ontologie bekommt eigene Instanz-Tabelle (zuvor nur temporär und nur eine Instanzmenge pro Element)

a)

```
<foaf:Person rdf:id="#a712561038">
  <rdfs:label>Marc Ehrig</rdfs:label>
  <foaf:name rdf:datatype="&xsd:string">Marc
  Ehrig</foaf:name>
  <foaf:firstName
  rdf:datatype="&xsd:string">Marc</foaf:firstName>
  <lastName rdf:datatype="&xsd:string">Ehrig</lastName>
</foaf:Person>
```

b)

```
<TFreizeit_Basteln_Window_Color
rdf:ID="http://www.bastelstore.de/">
  <rdfs:label>Bastelstore</rdfs:label>
  <rdfs:comment>Neben dem umfangreichen Window
  Color Sortiment werden Farben und Lacke fuer die
  Serviettentechnik angeboten.</rdfs:comment>
</Freizeit_Basteln_Window_Color>
```

zu a)

id	connect	elementid	Instance_id	attribute	value
11	a712561038	798	11	id	a712561038
12	a712561038	798	12	label	Marc Ehrig
13	a712561038	811	-1	[NULL]	Ehrig

zu b)

id	connect	elementid	Instance_id	attribute	value
20	http://www.bastelstore.de/	412	20	id	http://www.bastelstore.de/
21	http://www.bastelstore.de/	412	21	comment	Neben dem umfangreichen Window Color Sortiment werden Farben und Lacke fuer die Serviettentechnik angeboten.
22	http://www.bastelstore.de/	412	21	label	Bastelstore

Instanz-basiertes Matching mit Verwendung der URLs

- Motivation: URLs verschiedener Verzeichnisse überlappen sich
→ Grad der Überlappung wird zur Ähnlichkeitsberechnung genutzt
- URL-Vergleich basiert auf Gleichheit:
 - Grund: selbst kleine Unterschiede in URLs führen zu total verschiedenen Bedeutungen, z.B. Tuch vs. Buch vs. Busch
 - Vorverarbeitung wird ausgeführt, um mit unterschiedlichen Notierungen von URLs umzugehen

5 mögliche Vorverarbeitungsschritte:

- **Original:** komplette URLs, wie sie im Verzeichnis auftauchen
`http://www.Test.com/Shop/`
- **Simpl1:** "/" am Ende und Parameter nach "?" entfernen, Kleinschreibung
`http://www.test.com/shop`
- **Simpl2:** *Simpl1* + am Anfang "http://" and "www." entfernen
`test.com/shop`
- **Simpl3:** *Simpl2* + alles nach dem ersten "/" entfernen
`test.com`
- **Simpl4:** *Simpl3* + Domäne entfernen (alles nach dem letzten ".")
`test`

Ähnlichkeitsmaße für das URL-basierte Matching


Ähnlichkeitswerte $\in [0 \dots 1], \forall c_1 \in C_{D1}, c_2 \in C_{D2}$

- $Sim_{Base-k}(c_1, c_2) = \begin{cases} 1, & \text{if } |I_{c1} \cap I_{c2}| \geq k \\ 0, & \text{if } |I_{c1} \cap I_{c2}| < k \end{cases}$

- $Sim_{Min}(c_1, c_2) = \frac{|I_{c1} \cap I_{c2}|}{\min(|I_{c1}|, |I_{c2}|)}$

- $Sim_{Dice}(c_1, c_2) = \frac{2 \cdot |I_{c1} \cap I_{c2}|}{|I_{c1}| + |I_{c2}|}$

- $Sim_{Max}(c_1, c_2) = \frac{|I_{c1} \cap I_{c2}|}{\max(|I_{c1}|, |I_{c2}|)}$



$$Sim_{Base-1}(c_1, c_2) = 1$$

$$Sim_{Min}(c_1, c_2) = \frac{2}{2} = 1$$

$$Sim_{Dice}(c_1, c_2) = \frac{2 \cdot 2}{3 + 2} = 0.8$$

$$Sim_{Max}(c_1, c_2) = \frac{2}{3} = 0.67$$


$$Sim_{Base-1}(c_1, c_2) \geq Sim_{Min}(c_1, c_2) \geq Sim_{Dice}(c_1, c_2) \geq Sim_{Max}(c_1, c_2)$$

Datensätze

- Vier Webverzeichnisse, Beschränkung auf Onlineshops

	Dmoz	Google	Web	Yahoo
#Kategorien	746	728	418	3,234
# Kategorien mit direkt assoziierten Instanzen	738	720	380	3,143
#Instanzen	15,304	15,082	13,673	34,949
# Direkte Assoz. pro Kat.	21	21	36	11
Durschnittliche Länge URL / Name / Beschr.	28 / 21 / 119	29 / 20 / 119	28 / 26 / 92	28 / 11 / 70

- Instanzverteilung über die Kategorien




- Sechs Matchaufgaben → Sechs Referenzmappings (von Hand erstellt)

	Dmoz ↔ Google	Dmoz ↔ Web	Dmoz ↔ Yahoo	Google ↔ Web	Google ↔ Yahoo	Web ↔ Yahoo
# Korresp.	729	218	436	211	416	235
Abgedeckte Kategorien	98% ↔ 100%	29% ↔ 50%	55% ↔ 13%	29% ↔ 48%	55% ↔ 12%	52% ↔ 7%

Überlappung der URLs


- Insgesamt um die 60,000 verschiedenen URLs
- Anzahl der URLs, die sich in allen Verzeichnissen befinden: ~ 500



	Dmoz ↔ Google	Dmoz ↔ Web	Dmoz ↔ Yahoo	Google ↔ Weby	Google ↔ Yahoo	Web ↔ Yahoo
URL Überlappung (ohne Duplikate)	12,963	1,650	1,485	1,679	1,561	1,695
=Verzeichnis-URLs (mit Duplikaten)	85% ↔ 87%	11% ↔ 12%	10% ↔ 5%	11% ↔ 13%	10% ↔ 5%	13% ↔ 5%

Ergebnisse der Instanz-basierten Matcher


- URL-basierten Matching: **durchschnittlicher Fmeasure von 6 Matchaufgaben** für 5 Varianten der URL-Vorverarbeitung und 6 Ähnlichkeitsmaße



Für Dice und Max



- Besser als Min und Base-k
- URL-Vorverarbeitung mit Vereinfachung (Simpl1-Simpl4) besser als Original-URLs
- Profitieren von der zusätzlichen Verwendung von indirekten URLs

Höchster durchschnittlicher Fmeasure **0.6**: Dice, Simpl2, Direkte + Indirekte URLs



Produktkataloge - Aktueller Stand

- Produktkataloge: systematisch geordnete Sammlung von Informationen zu Produkten oder Dienstleistungen
- Auflistung erfolgt meist nach bestimmten Systematiken und Gruppierungen nach Eigenschaften
- Es existieren viele verschiedene Produktkataloge, z.B. Amazon oder Ebay



- Verschiedene Standardformate zum Austausch von Produktkatalogen, z.B. BMEcat und xCBL

Produktinformation

- Name
- Identifikationsnummern
 - Catalogintern, beispielsweise bei Amazon ASIN (Amazon Standard Identification Number) oder bei Ebay die Artikelnummer
 - Strichcode
 - Modellnummer
- Preis
- Beschreibung
- Größe
- Farbe
- Bewertungen
- Rangfolge beim Verkauf
- Bild(er)
- ...

ASIN: B000JNYWBG

Artikelnummer: 160249046656

Motorola MOTO SLVR L9 Handy ohne Branding
von Motorola
★★★★★ (12 Kundenrezensionen)
[Mehr zu diesem Artikel](#)

Preis: EUR 99,97 **Kostenlose Lieferung.** [Details](#)

Verfügbarkeit: Auf Lager. Verkauf und Versand durch **Amazon.de**. Geschenkverpackung verfügbar. Zustellung durch **Amazon**.

Nur noch 1 Stück verfügbar -- jetzt bestellen.

Lieferung bis Freitag, 20. Juni: Bestellen Sie in den nächsten 6 Stunden und 29 Minuten per **Overnight-Express**. [Siehe Details.](#)

15 Angebote erhältlich ab EUR 75,00

Technische Details

- 2-Megapixel-Kamera
- MicroSD-Karten-Steckplatz
- TFTT-Farbdisplay (176 x 220, 262 k)
- Bluetooth Klasse 2
- Lieferumfang: Handy, Akku, Bedienungsanleitung

Produktinformation

Größe und/oder Gewicht: 12 x 49 x 114 cm ; 400 g
Produktgewicht inkl. Verpackung: 440 g
Versand: Dieser Artikel kann nur in folgende Länder verschickt werden: Deutschland, Österreich

Menge: 1
[In den Einkaufswagen](#)
oder
Loggen Sie sich ein, um 1-Click® einzuschalten.

Alle Angebote

402use, Tränkle & Wahnberger GbR
EUR 99,90 + EUR 6,99
Versandkosten
Auf Lager.
[In den Einkaufswagen](#)

*electronic...
EUR 109,00 + Kostenlose Lieferung.
Auf Lager.
[In den Einkaufswagen](#)

limbastore_24
EUR 148,97 + EUR 4,95
Versandkosten
Auf Lager.
[In den Einkaufswagen](#)

15 Angebote ab EUR 75,00
Möchten Sie verkaufen?
[Diesen Artikel verkaufen](#)

[Auf meinen Wunschzettel](#)
[Auf die Hochzeitsliste](#)
[Einem Freund weitersagen](#)

Instanz-basiertes Matching über eindeutige ID

- Vorteil: Test auf Gleichheit (nicht Ähnlichkeit) → schnell, eindeutig
- Nachteil: Manche Produktkataloge verwenden UPC, andere EAN, manche beides
- Idee:
 - Nutzen des Wissens im Internet um “Wissenslücke” zu füllen
→ EAN, UPC, ASIN, Modellnummer, Produktname, Hersteller, ...

www.upc-codes.com
www.ean-codes.com
www.isbn-codes.com
www.model-numbers.com

0683728121587 - Apple iPod touch 16 GB without Software Updates



683728121587

Powered By IDAutomation.com

Publisher:
Manufacturer:
Manufacturer Part:
ASIN:
UPC:
EAN:

Apple Computer
Apple Computer
[MA627LL/A](#)
B000JNYWBG
[683728121587](#)
[0683728121587](#)
[Compare Prices on Apple iPod touch 16 GB without Software Updates at EAN Prices](#)

Prices:

Description:


Does not ship with the new software applications announced at MacWorld 2008; software upgrades are available via the online Apple store for \$20

Strichcodes

- Produktkennzeichnung für Handelsartikel

- **UPC**

- *Universal Product Code*, 12-stellig
- 1973 in USA eingeführt




- **EAN**

- *European Article Number*, 13-stellig (bzw. 8 für kleine Artikel)
- Kompatibel zu UPC
 - Ergänzung von einer UPC-Nummer um eine führende Null ergibt gültige EAN
 - UPC wird deshalb von international tätigen Firmen genutzt
- Kompatibel zu ISBN (Bücher) und ISSN (Zeitschriften)
 - EAN wird mit Hilfe der EAN-Ländernummer und Prüfziffer erzeugt



- **GTIN**

- *Global Trade Item Number*, 14-stellig
- Kompatibel zu UPC und EAN (führende Nullen)
- Zukünftiger Einsatz



Datensatz (bisher)

- Amazon und Yahoo (US) mit Beschränkung auf Elektronik

	Amazon	Yahoo
#Kategorien	2250	1855
#Kategorien mit direkt assoziierten Instanzen	1956	1525
#Direkte Instanzen, mit	201618	6144
UPC	157964	4843
EAN	161061	0
ISBN	290	0
ASIN	201618	0

Erste Ergebnisse

- Qualität des Zusatzwissen:
je mehr die IDs miteinander verlinkt sind, umso besser
- Folgende Daten basieren auf Daten von Amazon, Yahoo und Zusatzwissen

www.upc-codes.com
www.ean-codes.com
www.isbn-codes.com
www.model-numbers.com

	Anzahl	Nicht gefunden
EAN	164025	267
UPC	159156	429
ManufacturerPart	162547	-
ISBN	285	5
ASIN	207479	2153

- Weitere Erkenntnisse der Untersuchung:

- Die EAN, die einer UPC zugeordnet ist, entspricht nicht der UPC mit führender Null 3,1% (4929)
- ASIN ohne UPC, EAN und ManufacturerPart sind nur 3,2% (6740)

	EAN	UPC	ASIN	ISBN	ManufacturerPart
EAN	-	91,1%	100%	0%	85,4%
UPC	93,3%	-	100%	0%	86,8%
ASIN	81,4%	79,5%	-	0,1%	83,6%
ISBN	100%	8,8%	100%	-	19,6%
ManufacturerPart	83,9%	83,4%	100%	0%	-

Ausnutzung des Zusatzwissens


UPC	Originalwissen		Mit Zusatzwissen		Zusätzlich
Amazon	154237	← 0,7% (max. möglich: 3,1%)	155644	← 0,7%	+1407
Yahoo	4843		5060		+217
zusammen	158044	↻ 21,4%	159568	↻ 22,5%	+1524
überlappend	1036		1136		+100

EAN	Originalwissen		Mit Zusatzwissen		Zusätzlich
Amazon	158061	← 0%	160749	← 0,7%	+2688
Yahoo	0		4604		+4608
zusammen	158061	↻ 0%	164240	↻ 24,2%	+6179
überlappend	0		1113		+1113

Nutzung der IDs:

1. Instanz-basiertes Matching der Produktkataloge


- Extrahieren aus den Produktinformationen: EAN, UPC
- Für alle EANs und UPCs Bestimmen der zugehörigen UPC bzw. EAN
 - Verwendung des Wissens von Online-Datenbanken (mit Datenwiederverwendung von früheren Vorgängen)
 - Beachte: nicht jede EAN hat UPC (und umgedreht)
- Verwendung verschiedener Ähnlichkeitsfunktionen: Base-k, Min, Dice, Max



Nutzung der IDs:

2. Instanzassoziationen über weitere Quellen nutzen

- Webseiten, die Preisvergleich anbieten, verlinken zu einem Produkt bei verschiedenen Anbietern
- Diese Instanzassoziationen können über Compose zum Matching verwendet werden



Nächsten Schritte

- Extraktion weiterer Produktkataloge
- Test, ob mit Verwendung von Zusatzwissen neue Korrespondenzen mit Base-K generiert werden (ohne Mappings möglich)
 - wenn ja, dann Überprüfung ob diese korrekt
- Erstellung eines Mappings (n:m, Teilmengenbeziehungen?)
 - Ausnutzung der Metadaten und Instanzen
- Auswertung von Preisvergleichs-Websites (z.B. PriceSpider.com)
- ASIN führt zu ManufacturerPart, diese hat eigene Seite mit EAN bzw. UPC (und anderer ASIN)

Danke für die Aufmerksamkeit.

Fragen? Anmerkungen?

