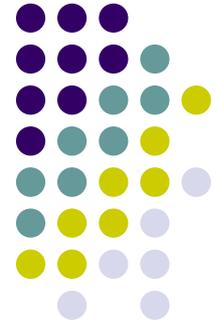


Web Mining und Farming

Shenwei Song



Gliederung

- **Übersicht über Web Mining und Farming**
- **Web Mining**
 - **Klassifikation des Web Mining**
 - **Wissensbasierte Wrapper-Induktion**
- **Web Farming**
 - **Übersicht über Web-Farming-Systeme**
 - **Verfeinerung der Web-Informationen**
- **Zusammenfassung**



Übersicht über Web Mining und Farming



- **Was ist Web Mining?**
 - Anwendung der Data-Mining-Technik zur automatischen Entdeckung und Extraktion der Informationen und Muster aus Web-Datenressourcen.
- **Warum Web Mining?**
 - Auffinden von neuen Kunden oder Geschäftsmöglichkeiten
 - Analysieren und Beobachten der Konkurrenz
 - Bedürfnisse web-basierter Applikationen besser erfüllen
- **Aufgaben des Web Mining**
 - Lokalisierung von Ressourcen
 - Extraktion von Informationen
 - Generalisierung von Mustern
 - Analyse der Muster

Übersicht über Web Mining und Farming



- **Was ist Web Farming?**
 - **Systematische** Verfeinerung der web-basierten Informationen für Business Intelligence
- **Warum Web Farming?**
 - Verbesserung der Leistung der Geschäftsaktivitäten
 - Optimierung des Workflow der Geschäftsaktivitäten
- **Aufgabe des Web Farming**
 - Verbesserung der Data Warehouses

Übersicht über Web Mining und Farming



- **Unterschiede** zwischen Web Mining und Web Farming

	Web Mining	Web Farming
Schwerpunkte	Entdeckung und Extraktion der Informationen und Muster	Nachbearbeitung der entdeckten Informationen aus Web-Daten
Arbeitsweise	Kurzzeitig und diskontinuierlich	Systematisch Langzeitig und kontinuierlich

Klassifikation des Web Mining



- Klassifikation des Web Mining nach benutzten Datentypen:
 - **Web Content**
 - Daten direkt aus Web-Seiten, z.B. HTML, Multimediadateien und Graphiken
 - **Web Structure**
 - Hyperlink-Struktur zwischen Web-Seiten
 - **Web Usage**
 - Beschreibung der Nutzung von Web-Ressourcen, z.B. Log-Dateien von Proxy-Servern und Web-Servern



Web Content Mining

- Entdeckung nützlicher Informationen aus Web Content
- Zerlegung in zwei unterschiedliche Sichten
 - **Information-Retrieval-Sicht**
 - **Datenbanksicht**



Web Content Mining

- **Information-Retrieval-Sicht**
 - Unterstützung des Auffindens der Informationen oder der Filterung der Informationen
 - **Hauptdaten** **Darstellung**
(Hyper-)Textdokumente → Ausdrücke, Beziehungen, Wortmengen
 - **Applikation:**
 - Dokument-Kategorisierung
 - Auffinden der Muster in Texten
 - Auffinden der Extraktionsregeln



Web Content Mining

- **Datenbanksicht**

- Modellierung der Daten für Netzanwendungen und Integration der Daten im Netz, um **komplizierte** Abfragen auszuführen
- **Hauptdaten** **Darstellung**
Hypertext-Dokumente → Beziehungen,
Edge-Labeled Graph
- **Applikation:**
 - Auffinden von frequenten Substrukturen
 - Entdeckung von Web-Seiten-Schemata



Web Structure Mining

- Entdeckung des Modells der Verweisstruktur des Web
- **Hauptdaten** **Darstellung**
Linkstrukturen → Graphen
- **Applikation**
 - Generierung von Information über Unterschied und Ähnlichkeit zwischen den Web-Seiten
 - Maß der Vollständigkeit der Web-Seiten
 - Maß der Relevanz der Web-Seiten



Web Usage Mining

- Entdeckung der Zugriffsmuster
- Sammlung der Informationen über Benutzerverhalten
- Hauptdaten
Server/Browser Logs → Darstellung
Graphen, relationale Tabellen
- Applikation
 - Konstruktion von Web-Seiten
 - Marketing
 - Benutzer-Modellierung



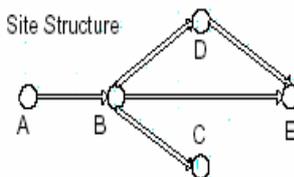
Web Usage Mining

- Beispiel der indirekten Beziehung aus Web-Usage-Daten

Web sessions

Session Id	Sequence
1	<A,B,C,B,D>
2	<A,B,E>
3	<B,C>
4	<A,B,E,B,D>
5	<B,D,B,C>

Site Structure



Support of all 2-itemset
(Frequent itemsets are shaded)

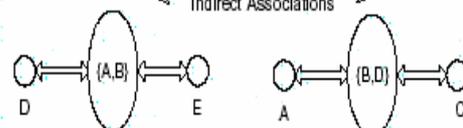
Pattern	Support
{A,B}	3
{A,C}	1
{A,D}	2
{A,E}	2
{B,C}	3
{B,D}	3
{B,E}	2
{C,D}	2
{C,E}	0
{D,E}	1

Minsup = 40%

Frequent 3-itemset

Pattern	Support
{A,B,D}	2
{A,B,E}	2
{B,C,D}	2

Indirect Associations



Wissensbasierte Wrapper-Induktion



- **Informationsextraktion**

- Das Wiedererkennen und die Extraktion spezifischer Datenfragmente aus Dokumentensammlungen
- Beispiel: Identifizierung von Datum, Ort und Temperaturwert aus Wettervoraussage

- **Wrapper**

- Eine Regel oder eine Prozedur zur Extraktion von Information aus einer Informationsquelle
- Auf Informationsquellen einer einzigen Art spezialisiert

Wissensbasierte Wrapper-Induktion



- **Kategorien der Wrapper-Generierung**

- **Manuelle Wrapper-Generierung**
 - Festlegung von Extraktionsregeln von Menschen nach einer sorgfältigen Überprüfung von Beispiel-Web-Seiten
 - Hochpräzise Leistung, aber nicht automatisch anpassbar
- **Wrapper-Induktion**
 - Automatische Bildung eines Wrappers durch Lernen aus Beispielseiten einer Informationsquelle
 - Zwei Typen:
 - **Heuristische Wrapper-Induktion**
 - **Wissensbasierte Wrapper-Induktion**

Heuristische Wrapper-Induktion



- Wrapper-Induktion auf Heuristiken basierend
- Einsatz in den meisten traditionellen Systemen
- Manchmal nicht effizient, da die Heuristiken einfach und naiv sein können.

Wissensbasierte Wrapper-Induktion



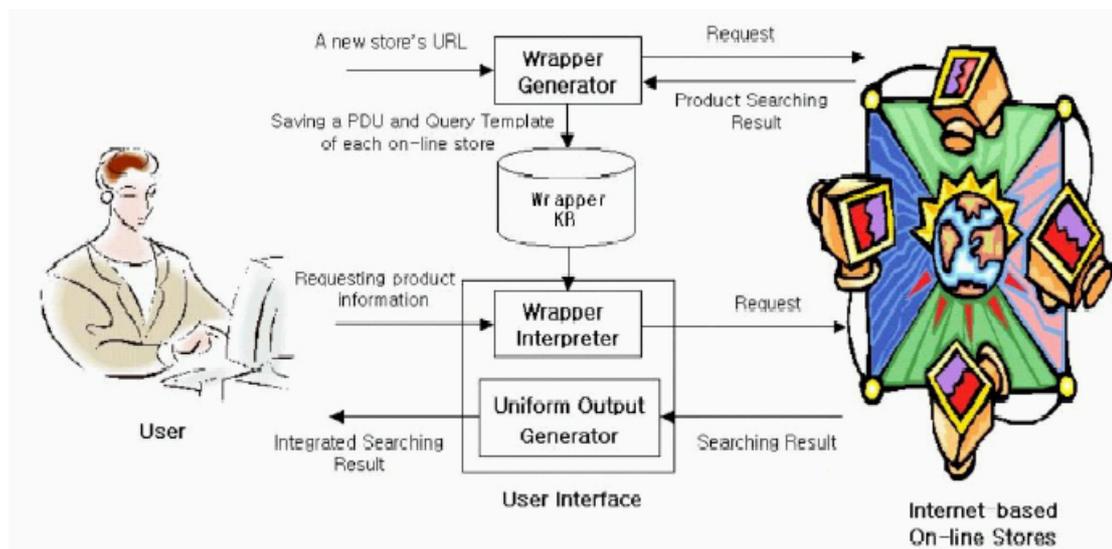
- Manuelle Generierung und Repräsentation der **Domänenkenntnis**
 - Beschreibung von Terme, Konzept, und Beziehungen
 - Erkennung semantischer Fragmente eines Dokument
- Definition und Anwendung der Domänenkenntnis während Wrapper-Generierung
- Automatische Bildung eines Wrappers durch Benutzung der Domänenkenntnis



XTROS

- Wissensbasiertes Informationsextraktionssystem
- Repräsentation der Domänenkenntnis und Wrapper mit XML
 - Flexibilität und Modularität
 - Portabilität und Mitbenutzbarkeit
- Extraktion von Informationen aus Dokumenten

Übersicht über XTROS





Domänenkenntnis-Beispiel

#1 Home for Sale:
LOS ANGELES, CA 90077
Residential

 Old World Grace, New World ...
\$3195000 ; 5 BR ;
5 BA ; 5000 sf ;
MLS ID: #P209731

Prop. ID #4460314

[Add Bookmark](#) | [Mortgage Calculator](#) | [View Property](#)

Features:
- Area Facts - Map View

```
<KNOWLEDGE>
<OBJECTS>
<OBJECT>PRICE</OBJECT>
<OBJECT>BED</OBJECT>
<OBJECT>BATH</OBJECT>
<OBJECT>CITY</OBJECT>
<OBJECT>MLS</OBJECT>
<OBJECT>DETAIL</OBJECT>
<OBJECT>IMG</OBJECT>
</OBJECTS>
<PRICE>
<ONTOLOGY>
<TERM>PRICE</TERM>
<TERM>$</TERM>
<TERM>PRICE $</TERM>
</ONTOLOGY>
<FORMAT>
<FORM>[ONTOLOGY] DIGITS</FORM>
<FORM>DIGITS [ONTOLOGY]</FORM>
</FORMAT>
</PRICE>
```

```
<BED>
<ONTOLOGY>
<TERM>BEDROOM</TERM>
<TERM>BED</TERM>
<TERM>BEDS:</TERM>
<TERM>BR</TERM>
<TERM>BEDROOMS</TERM>
<TERM>BD,</TERM>
</ONTOLOGY>
<FORMAT>
<FORM>DIGITS [ONTOLOGY]</FORM>
<FORM>[ONTOLOGY] DIGITS</FORM>
</FORMAT>
</BED>
----- omitted -----
</KNOWLEDGE>
```

Wissensbasierter Wrapper-Generierungsalgorithmus



- Erste Phase
 - Konvertierung der HTML-Quelle in **logische Linien**
- Zweite Phase
 - Bestimmung der Bedeutung der logischen Linien durch Einsatz der Domänenkenntnis
 - Kategorisierung der logische Linien
- Dritte Phase
 - Auffinden der **am häufigsten benutzten Muster** in **Sequenz der Katalognummern**

Konvertierung der HTML-Quelle in Logische Lininen



HTML source before pre-processing for www.homes.com

```
#1<BR> </B></FONT><!--Address: 1861 Bel Air Rd ZipCode: 90077 --> </TD>
<TD BGCOLOR="D6E3AA" <FONT FACE="Verdana,Arial,Helvetica" SIZE="1"
<B>&nbsp;:Home for Sale:<BR> &nbsp;:LOS ANGELES, CA</B> &nbsp;:90077 <BR> ...
<TR VALIGN="TOP" > <TD BGCOLOR="D6E3AA" <FONT FACE="Verdana,Arial,Helvetic...
<FONT FACE="Verdana,Arial,Helvetica" SIZE="1" &nbsp;:Residential<BR></FONT> ...
<IMG SRC="http://a1572.g.akamai.net/7/1572/608/20000614144425/thcms01,hom ...
<TABLE WIDTH="100%" CELLPADDING="0" CELLSPACING="0" BORDER="0" > ...
<A HREF="/HomesCom/Content/ListingDetail/1,3178,,00.html?City=LOS+ANGELES...
<IMG ALT="View Details" WIDTH="90" HEIGHT="59" BORDER="0" SRC=...
<TD VALIGN="CENTER" BGCOLOR="FFFFFF" <FONT FACE="Verdana,Arial,Helvetica" ...
$3195000 ; 5&nbsp;:BR ; <BR> 5&nbsp;:BA : 5000&nbsp;:sf ; <BR> MLS ID:&nbsp;:# P...
</FONT> </TD> </TR>
```



HTML source after pre-processing for www.homes.com

```
#1
Home for Sale: LOS ANGELES, CA 90077 Residential
<IMG SRC="http://a1572.g.akamai.net/7/1572/608/20000614144425/thcms01, ...
<A HREF="/HomesCom/Content/ListingDetail/1,3178,,00.html?City=LOS+ANGE ... </A>
<A HREF="/HomesCom/Content/ListingDetail/1,3178,,00.html?City=LOS+ANGE ... </A>
$3195000 ; 5BR ; 5BA : 5000sf ; MLS ID:#P209731
```

Bestimmung der Bedeutung logischer Lininen



No.	object	line	cat	type	format
1	{{IMG}}	< A HREF=" .. "> <<IMG[{{ALT=" .. "}}]> <<IMG}}	6	IMGURL	[ONTOLOGY] IMGURL
2	{{PRICE}}	{{[[\$]}3195000} <<PRICE}}	0	DIGITS	[ONTOLOGY] DIGITS
3	{{BED}}	; {{[{{BR}}]} {{BED}}	1	DIGITS	DIGITS [ONTOLOGY]
4	{{BATH}}	; {{[{{BA}}]} {{BATH}}	2	DIGITS	DIGITS [ONTOLOGY]
5	{{MLS}}	; 5000sf ; <<[{{MLS ID:#}}] P209731} <<MLS}}	4	DIGITS	[ONTOLOGY] DIGITS
6	{{DETAIL}}	<< A HREF=" .. "> <<[View Property]} <<DETAIL}}	5	URL	URL [ONTOLOGY]

Auffinden der am häufigsten benutzten Muster



- Algorithmus:
 - Auffinden aller **Kandidatenmuster** aus **Sequenz** (maximale Substring)
 - Mindesten drei Attribute
 - Ohne duplizierte Attribute
 - **Fp**: Frequenz eines Kandidatenmusters in der Sequenz
 - **Ap**: Anzahl der Attribute in einem Muster
 - **Tp**: Gesamte Anzahl der Attribute des Musters
 - $Tp = Fp * Ap$

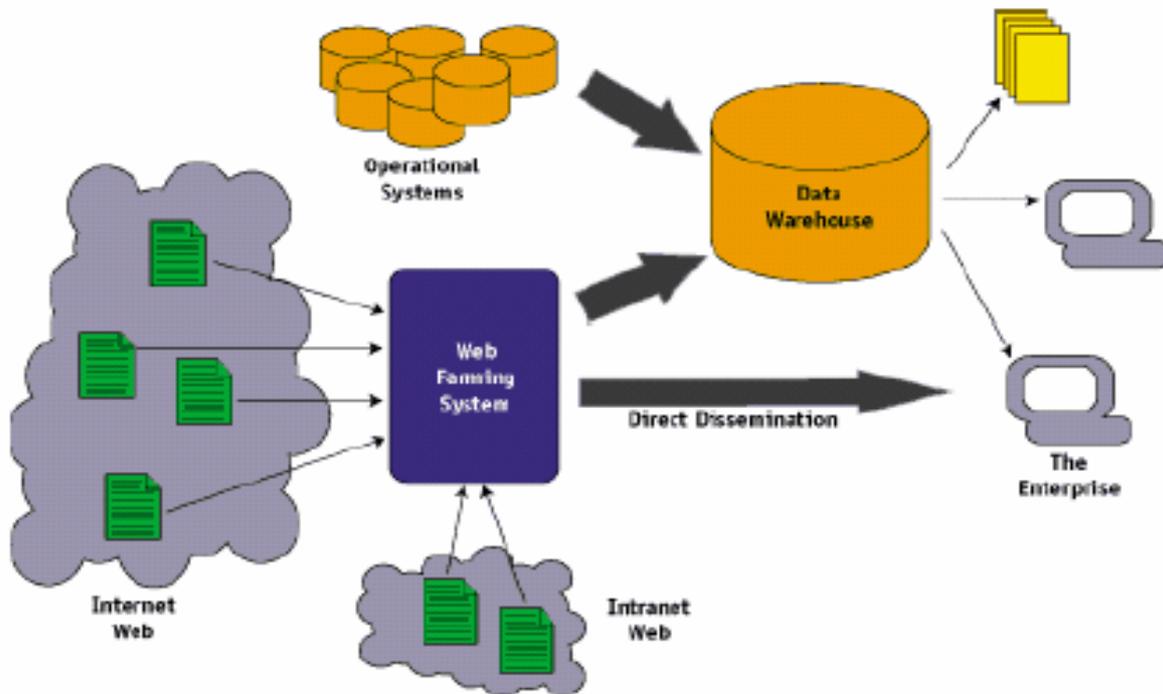
Beispiel der am häufigsten benutzten Muster



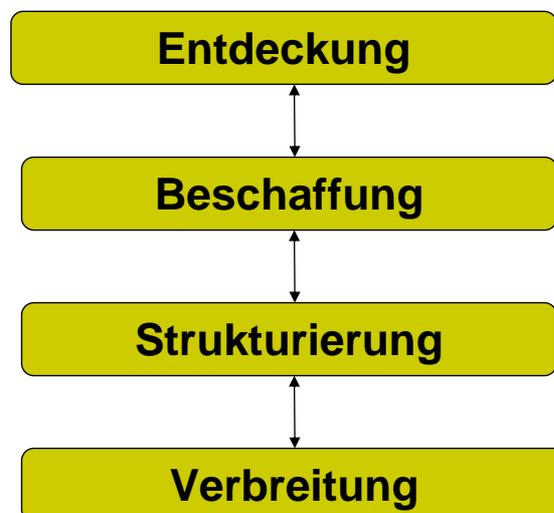
- Sequenz
 - 601245601245601245601245601245

Kandidatenmuster	Muster Frequenz (Fp)	Anzahl der Attribute des Muster (Ap)	Gesamt Anzahl der Attribute des Muster (Tp=Ap*Fp)
601245	5	6	30
012456	4	6	24
124560	4	6	24
245601	4	6	24
456012	4	6	24
560124	4	6	24
56012	5	5	25
60125	1	5	5
01256	1	5	5
12506	1	5	5
25601	1	5	5
01245	5	5	25
1245	5	4	20
245	5	3	15

Übersicht über Web-Farming-Systeme



Verfeinerung der Web-Information



Verfeinerung der Web-Information



- **Entdeckung**
 - Lokalisierung von Individuen und Organisationen
- **Beschaffung**
 - Sammlung und Erhaltung von identifiziertem Inhalt
- **Strukturierung**
 - Analyse und Transformation des Inhalts in nützliche Form und Struktur
- **Verbreitung**
 - Verpackung und Lieferung der Informationen zum entsprechenden Verbraucher

Zusammenfassung



- **Übersicht über Web Mining und Farming**
- **Web Mining**
 - **Klassifikation des Web Mining**
 - **Wissensbasierte Wrapper-Induktion**
- **Web Farming**
 - **Übersicht über Web-Farming-Systeme**
 - **Verfeinerung der Web-Informationen**