

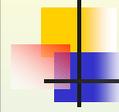
## Konzepte der AI

---

Informationsagenten/systeme im  
Internet

**DBAI**  
**DBAI**

*Robert Baumgartner*



## Klassifikation nach Ausführungsort

---

- *Internetagenten:* Websuchagenten, Web-Serveragenten, Informationsfilteragenten, Informationsbeschaffungsagenten, Notification Agenten, Service-Agenten, Mobile Agenten
- *Intranetagenten:* Kollaborative Anpassungsagenten, Prozeßautomatisierungsagenten, Datenbankagenten, Resourcebrokeringagenten
- *Desktopagenten:* Interface-Agenten für OS, Applikationen etc.



## Bots, Spiders und Agenten

---

- Bots: unbeachtete Programme die auf das Internet zugreifen
- Spiders: Bots die bestimmte Webseiten durchsuchen; Spider scannen das Netz kontinuierlich und folgen den Links auf den Seiten (crawling); Verwendung in Suchprogrammen wie Altavista, Excite
- Intelligent Agents: Bots mit höherer Intelligenz und interaktiven Komponenten

*Gute Agenten halten sich an die Robot Exclusion Standards (robots.txt und robot meta tags) und melden sich als passender User-Agent mit email-Adresse an.*

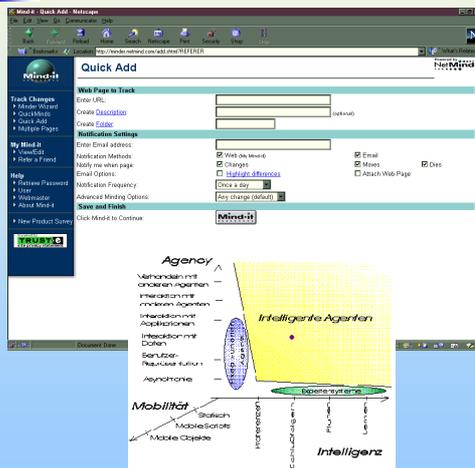


## Beispiele

---

- **News Bot:** beobachtet ohne Einwirken des Users diverse online News Items und verständigt den User bei Neuigkeiten; Interaktion mit dem User
- **Projekt Softbot:** verwendet Planen und maschinelles Lernen und entscheidet selbst wie und wo vom User gewünschte Informationen gewonnen werden
- **Letizia:** beobachtet User bei Verwendung eines Browsers und ahmt nach, versucht herauszufinden welche Links den Benutzer am meisten interessieren
- **Beispiel eines Nichtinternet-Informationsagenten:** Erinnerungsagent, der User einmal pro Stunde an eine fünfminütige Pause erinnert; Richtlinien: einfaches Deaktivieren/Aktivieren und User sonst nicht stören

# MindIt-Agent



- zur Überwachung von Änderungen auf Webseiten
- statischer Notification/Interface Agent, Interaktion mit Daten, Präferenzen und Schlußfolgern

- Umgang mit Updates
- htmldiff tools, Update Monitoring (z.B. Continual Queries Projekt: Trigger welche Änderungen relevant)

# Funktionen und Komponenten

## ■ Funktionen

- Aufgabenausführung
- Wissensverarbeitung
- Kommunikationsfähigkeit (mit Nutzer)

## ■ Komponenten

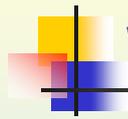
- Persönliches Profil (Informationsbeschreibg.sprache XML,...)
- Schnittstellen zu Diensten (CORBA,... und ACL)
- Aufgabenbeschreibungen/Missionsskripts (Java, Tcl, Perl,...)



## Intelligente Internetsysteme

---

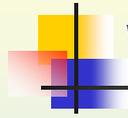
- Usermodellierung
- Finden und Analyse
  - Auffinden
  - Extrahieren (parsen, wrappen)
  - Übersetzen (Semantik geben)
  - Auswerten
- Informationsintegration
- Webseitenmanagement



## Wichtige Grundbegriffe

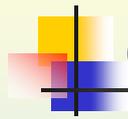
---

- IP-Adressen  
identifizieren jeden Rechner eindeutig im Netz; Multicast-Adressen
- TCP und UDP Protokoll  
Transport Control Protocol, User Datagram Protocol
- CGI  
Common Gateway Interface Scripts
- SQL,...  
Structured Query Language (Datenbankkommunikation)
- Parsen von Text,...
- CORBA  
Common Object Request Broker Architecture  
- Standard für komponentenbasierte Software-Entwicklung  
- Abstraktion über primitive Netzwerkdienste Middleware



## Wichtige Grundbegriffe (2)

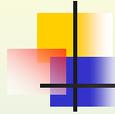
- **HTTP, FTP, WAP,...**  
Hypertexttransfer Protocol, File Transfer Protocol
- **SGML** (Standard Generalized Markup Language) ist ein internationaler Standard die Struktur und den Inhalt maschinell lesbarer Information zu beschreiben. SGML "Dokumente" bestehen aus Text, Grafik und Hypertextlinks.
- **XML** ist ein einfacher Dialekt von SGML der für WWW/Intranet entworfen wurde. XML ist eine Teilmenge von SGML.
- **HMTL** ist eine SGML-Applikation
- **XSL(T): Extensible Stylesheet Language**  
ist eine Sprache um XML zu transformieren und formatieren
- **Resource Description Framework RDF**  
stellt eine allgemeine Methode zur Verfügung um Metadaten für XML Dokumente zu beschreiben (Ressourcen, Eigenschaften, Aussagen)



## eXtensible Markup Language

- Informationsbeschreibungssprache für Agenten
- frei definierbare Tags
- selbstbeschreibend (wenn keine DTD: well-formed XML)
- layoutunabhängig (Trennung von Layout und Markup; Separater Mechanismus zur Visualisierung)
- Document Type Definition legt Grammatikregeln fest (wenn konform zu DTD und well-formed: valides XML)
- Beispiel (Elemente `title` etc., Attribute `currency`)

```
<book><title>The Lord of the Rings</title>
<author>
  <firstname>John Ronald Reuel</firstname>
  <lastname>Tolkien</lastname>
</author>
<price currency="USD">9.25</price></book>
```



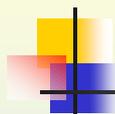
## DTD

```
<!ELEMENT book (title,author+,price)>
<!ELEMENT title (#PCDATA)>
<!ELEMENT author (#PCDATA | lastname | firstname | fullname)*>
<!ELEMENT price (#PCDATA)>
<!ATTLIST price
            currency CDATA "USD"
            source (list|regular|sale) "list"
            taxed CDATA #FIXED "yes">
<!ELEMENT lastname (#PCDATA)>
<!ELEMENT firstname (#PCDATA)>
<!ELEMENT fullname (#PCDATA)>
```

+ drückt Möglichkeit mehrerer Autoren aus. \* null oder öfter  
PCDATA (parsed character data, i.e. daß Markup innerhalb  
nicht erwähnte Elemente sind durch die DTD nicht beschränkt.

Default Währung ist hier US-Dollar, source kann drei Werte haben  
und default list; und taxed hat hier den Fixwert ja. Attribute müssen  
nicht spezifiziert werden (außer bei #REQUIRED)

Spezielle Linkattribute: id, idref      Entitäten: Textbausteine



## Rund um XML

- XPath (Adressierung von XML Dokument-Teilen)
- XPointer, XLink (Verbinden von Objekten in XML Dokumenten)
- XML Schema (Erweiterung von DTDs)
- DOM (API für Navigation und Manipulation in Dokumentstruktur)
- Querysprachen (XML-QL, XQL, XML-GL, Lore, XQuery)

```
WHERE <book>
    <publisher><name>Addison-Wesley</></>
    <title> $t </>
    <author> $a </>
</> IN www.text.edu/bib.xml
CONSTRUCT $a
```



## XSL

---

- navigiert Dokument mittels XPath
- formatiert (z.B. HTML Output), strukturiert und führt Funktionen aus
- Strukturelle Rekursion
- auch als Querysprache geeignet
- ist programmiersprachenvollständig



## Sprachen für Internetagenten

---

- *Smalltalk* - frühe AI-Sprache
- *Tcl/Tk* - interpretierte Skriptsprache. Tk ist graphisches User Interface; Agent-Tcl Erweiterung für mobile Agenten
- *Perl* - Skriptsprache mit C-artiger Syntax und einer reichhaltigen Ansammlung von Modulen
- *Telescript* - objektorientierte Sprache für mobile Agentensysteme; Nachfolger: Odyssee (beide nichtmehr verfügbar)
- *C, C++, etc...*
- *ECMA Script* (Java-Script, objektorientierte Skriptsprache, keine Parallelität)
- *Java*



## Java

---

- objektorientiert
- interpretiert (Java Bytecode)
- Virtuelle Maschine ist maschinenunabhängig
- verfügbar für viele Plattformen
- erlaubt multiple threads
- Remote Method Invocation
- Security Manager
- praktische Klassen: `java.net`, `javax.swing`, `HTMLToolkit`,...
- Java Tutorial: <http://java.sun.com>
- Applets, Servlets



## Java (2)

---

*aufbauend auf Java:*

- IBM Aglets (für mobile Agenten)
- ZEUS, Impact (für Multi-Agentensysteme)
- Jedi (Wrapping Semistructured Data)



## Bsp.: IP-Adresse des lokalen Rechners eruien

```
import java.net.InetAddress;
import java.net.UnknownHostException;

public class get {
    public static void main(String[] args) throws
    UnknownHostException {
        InetAddress local = InetAddress.getLocalHost();
        System.out.println(local.getHostAddress());
        System.out.println(local.getHostName());
    }
}
```

*Beispiel* ↩



## Bsp.: Browser

*Ein kleiner Browser mit Swing (ohne Hyperlink folgen; ohne Scrollbars)*

```
import java.io.*;
import java.net.*;
import javax.swing.*;

public class view extends JPanel {
    public static void main (String args[]) throws Exception {
        JFrame f = new JFrame("Viewer");
        URL url = new URL(args[0]);
        JEditorPane p = new JEditorPane();
        p.setPage(url); p.setEditable(false);
        f.getContentPane().add(p); f.setSize(640,480); f.show();
    }
}
```

*Beispiel* ↩



## Perl

- Skriptsprache
- legt keinerlei unnötigen Beschränkungen auf
- Regular Expressions, Pattern Matching
- Mächtige Manipulationsoperatoren (Substitution, Translation)

*Beispiel:*

```
print "What is your name?";
$name = <STDIN>;
chomp ($name) ;
print "Hello, $name!\n";
```



## Semistrukturierte Daten

- Für Datenextraktion vom Web und Update Monitoring von Webseiten ist es nötig, daß Agenten mit semistrukturierten Daten umgehen, da HTML Seiten gleichen Types semistrukturierte Daten darstellen
- Semistrukturierte Daten haben gewisse Struktur, passen aber nicht in ein relationales oder objektorientiertes Datenbankschema (selbstbeschreibend)

- **Ansätze:**

- **eigenes Datenbankschema**

- z.B. Lore (Lightweight Object Repository); aber auch XML ist semistrukturiert

- **Wrapper um Daten herumbauen**

- um sie in Struktur einzuhüllen die für Queries verwendet wird; für Wrappergenerierung gibt es große Anzahl an Tools/Papers, die für Agenten verwendet werden können (Jedi, Florid, Tsimmis,...)

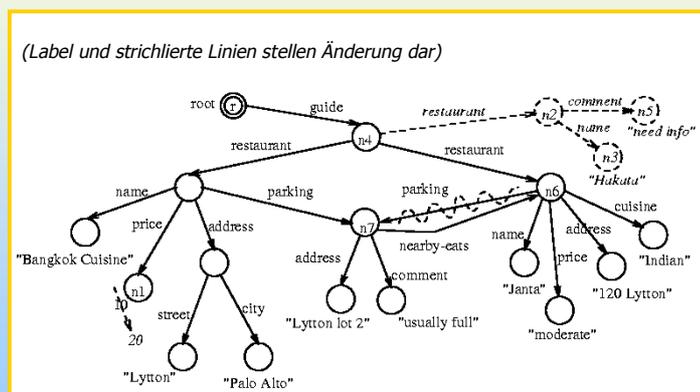


## OEM – Object Exchange Model

- Datenmodell für semistrukturierte Daten
- Daten als gerichteter Graph; Objekte als Knoten
- von Objekt ausgehende Kanten stellen Attribute des Objekts dar
- Atomare und komplexe Objekte  
Atomare Objekte sind vom Typ String, Integer etc. und stellen Blätter dar
- Der Graph hat mindestens eine Wurzel
- flache und tiefe Gleichheit
- Änderungen darstellbar (Delta OEM): Operationen wie Create Node; annotated nodes; *Chorel* als Erweiterung zu *Lorel*



## OEM - Beispiel





## Lore

- verwendet OEM
- leicht für XML adaptierbar
- verwendet Data Guides

kurze und exakte Übersicht der Struktur einer Datenbank, z.B. ein abstrahierter OEM Graph. exakte und approximierte Dataguides; zur Ähnlichkeitsabschätzung wird Object Matching und Role Matching verwendet (wenn keine DTD vorliegt)

- Anfragesprache Lorel

```
select M.Büro
from Abteilung.Mitarbeiter M
where M.Alter>40
```



## Notebook Kauf

Benutzer möchte sich über Notebooks informieren

- die weniger als öS 20000 kosten
- nicht von Firma X
- mindestens 128 MB RAM

Problem: lange mühselige manuelle Suche

- bestenfalls beschränkte Querymöglichkeiten
- keine site-übergreifenden Queries



Lösungsansatz:

- Wrappertechnologie für jede Art von Webseite
- Extrahierte Daten in selbes XML Schema abbilden
- Informationsmediator für flexible Queries nun leicht realisierbar
- Automatische Queries: z.B. Benutzerinfo via email



## Mediator

---

- Ein Informationsmediator stellt ein **query-only intermediate layer** zwischen den Clients und einer großen Anzahl von heterogenen Quellen dar. Darunter finden sich etwa verschiedene Arten von strukturierten Datenbanken als auch semistrukturierte Websourcen bzw. Textdateien.
- Clients von Informations Mediatoren können Informationsquellen abfragen und die Resultate **integrieren** ohne über Implementationsdetails wie Adressen, Formate, Sprachen, Plattformen Bescheid zu wissen.
- Das Informationsmediationssystem entscheidet bei einer gegebenen Query **welche Informationsquellen** verwendet werden, wie die gewünschte Information beschafft wird, wie und wo sie zwischengespeichert wird und wie Daten manipuliert werden.
- Informations Mediatoren sind **flexibler und erweiterbarer** als traditionelle Multidatenbankansätze, weil sie dynamische Integration der relevanten Informationsquellen als Antwort einer Query durchführen können.



## Wrapper

---

- Informations-Mediatoren benötigen Wrapper um Daten aus dem Web zu extrahieren.
- Hauptaufgabe: Information aus einer gegebenen Menge von Webseiten extrahieren und die Resultate als *(semi)strukturierte Datentupel* wiedergeben (z.B. in XML)
- Informations Extraktions Problem; ein Wrapper kann die Regularität des Erscheinungsbildes anstelle linguistischer Information verwenden
- Ein Wrapper für eine Klasse von Quellen

Back Forward Reload Home Search Netscape Print Security Shop Stop

Location: file:///H:/Auto/istocd/examples/ebaycom/ebay\_rb.html

notebook all of eBay - includes all regions Search more search options Results by: THE NUMBER

Search titles and descriptions (to find more items!) Search Completed Items eBay official time 02:25:2

2150 items found for "notebook". Showing items 1 to 50. Sort: Items ending first

Item#	Item	Price	Bids	Ends PDT
409449118	<a href="#">98 Degrees - Notebook - New</a>	\$2.99	-	in 19
413171469	<a href="#">Notebook - Compaq Presario 1207</a>	AU \$730.00	6	Aug-21 0
409454540	<a href="#">Compaq Armada Notebook P-100 Wm 95</a>	\$107.50	8	Aug-21 0
409456450	<a href="#">THE NOTEBOOK NICHOLAS SPARKS HARDCOVER</a>	\$5.50	2	Aug-21 0

```

<?xml version="1.0" encoding="UTF-8"?>
<document>
  <record>
    <number>409449118</number>
    <item>98 Degrees - Notebook - New</item>
    <picture/>
    <price>2.99</price>
    <currency>$</currency>
    <bids>-</bids>
  </record>
  <record>
    <number>413171469</number>
    <item>Notebook - Compaq Presario 1207</item>
    <price>730.00</price>
    <currency>AU $</currency>
  </record>
  [...]

```

## Wrapper Ansätze

- **manuell**  
geeignete Skriptsprache die die Extraktionsprache implementiert
- **automatisch**  
machine und pattern learning  
Lernalgorithmen basierend auf Beispielen  
Generalisierungs-/Spezialisierungs-Algorithmen
- **überwacht**  
interaktive geleitete Erstellung  
angeben von Kriterien

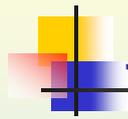


## Ansätze zur Extraktion

---

Wrapper - einige Seiten gleichen Aufbaus (wie eBay Seiten) werden analysiert und die Struktur z.B. mit kontextfreier oder regulärer Sprache beschrieben oder Automaten, versch. Ansätze im Detail:

- reguläre Grammatiken verwenden
- logische Programmierung
- mehrdeutige kontextfreie Grammatiken
- delimiter: Start und Ende Tags
- skipto-Sequenzen
- Finite State Transducer, endliche Automaten
- hierarchisch (HTML Parsebaum navigieren)
- Ontologien



## Jedi

---

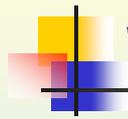
- erlaubt Wrappergenerierung für einen Typus von HTML-Dokument (Erstellung einer Skriptdatei)
- besteht aus handcodierten *Wrapper* (sammelt Daten durch Navigation durch verschiedene Dokumente unter Berücksichtigung ihrer logischen Struktur) und *Mediator* der die heterogenen Informationen integriert.
- verwendet als Regelsprache mehrdeutige kontextfreie Grammatiken und Parsing-Strategie die diese Mehrdeutigkeiten in sinnvoller Art und Weise auflöst.
- Mediator verwendet ein allgemeines Objekt-Modell, das auch erlaubt mit strukturellen Abweichungen umzugehen



## Stalker

---

- benutzermarkierte Beispiele
- semiautomatische Wrappergenerierung
- embedded catalogs Hierarchie
- in einer Sequenz von Tokens mit skipto Sequenzen von links und rechts arbeiten um Element zu finden
- z.B. SkipTo(<b>)SkipTo(,)
- (bzw. als endlicher Automat darstellen)
- Stalker-Algorithmus erstellt und optimiert Disjunktion von SkipTo Sequenzen aus den gegebenen Beispielen mit diversen Verfeinerungen bis bei möglichst allen Beispielen positiv
- beginnt mit kurzer SkipTo Sequenz und verfeinert (umgekehrte Richtung wäre ebenso möglich, Maximierung)



## Weitere induktive Ansätze

---

- NoDOSE  
automatische Datenextraktion aus Textquellen mit interaktivem Interface zur Angabe von negativen und positiven Beispielen
- RoadRunner  
Automatische Informationsextraktion ohne markierte Beispiele Datenfelder und Struktur werden erkannt
- MIA  
Multiagentenarchitektur, basierend auf Logikprogrammierung; durchsucht webseiten nach zB Restaurants in Umgebung; neurales Netzwerk für Textklassifizierung; verwendet Unifikation

*Vorteile:* stark automatisiert

*Nachteile:* weniger flexibel

viele Beispiele nötig

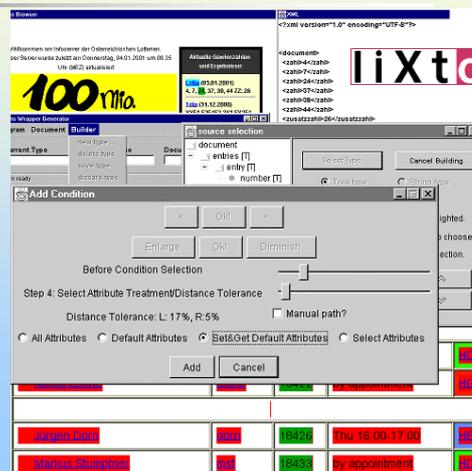
ist Beispielmenge ausreichend?

# Überwachte Wrappergenerierung

- XWrap (Liu et al.)
  - einige Erkennungsheuristiken
  - semi-automatisch, und nur tw. visuell
  - prozedurales Wrapperprogramm
  - "Templates" statt Vielzahl von Bedingungen
  - Variableniteration; Baumnavigation; keine Stringextraktion
  - semantische Tokens
- W4F (Azavant, Sahuguet)
  - deklarative Sprache HEL ("SQL-artige Aussagen")
  - Baum- und Stringnavigation
  - beschränktes UI
  - Hierarchische Extraktion, Bedingungen nicht strikt hierarchisch
  - verwendet XML-QL für Weiterverarbeitung

# Lixto Suite

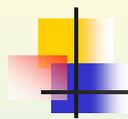
- Lixto Visual Wrapper  
[www.dbai.tuwien.ac.at/proj/lixto](http://www.dbai.tuwien.ac.at/proj/lixto)
- Infopipes (Lixto TS)  
personalisierbare Informationskanäle;  
source;wrapper;merger;transformer;  
deliverer
- Möglichkeit zu Praktika und  
Diplomarbeiten



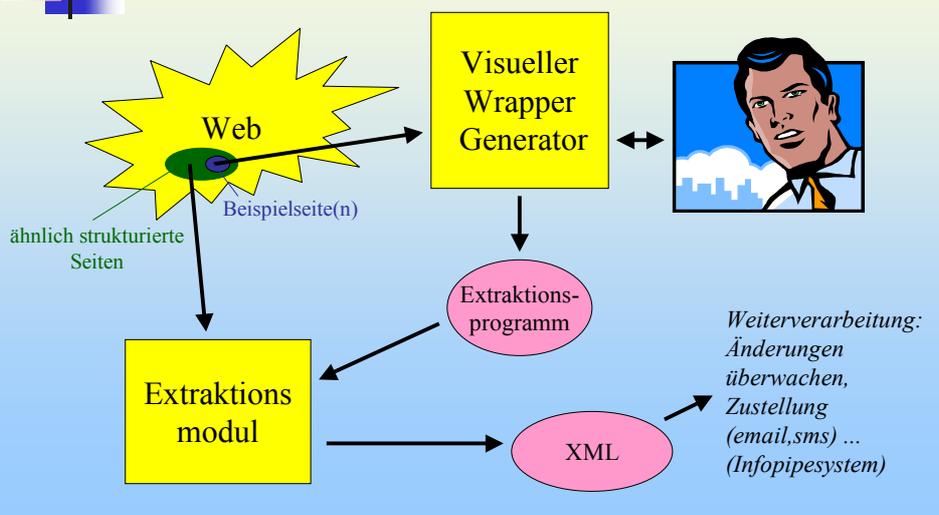


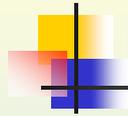
## Lixto Visual Wrapper

- An unserem Institut entwickelte Methode zur überwachten Wrappergenerierung
- visuelles interaktives UI
- Vielzahl von Bedingungen visuell festlegbar  
inner und outer conditions, range, types, concepts
- multiple area matching, single area matching
- hierarchische Baumnavigation und Textnavigation
- "unsichtbare" deklarative Extraktionsprache
- implementiert in Java mit Swing-Klassen
- kontinuierliche Extraktion: "XML Companion"
- eingebettet in IP System



## LiXto VW Architektur





## Lixto Wrappergenerierung

- Patterngenerierungsalgorithmus
  - Ein Pattern charakterisiert eine Art von Information
  - Benutzer erstellt interaktiv Pattern aus einer Anzahl von Filtern. Jeder Filter kann aus mehreren Bedingungen bestehen.
  - Filter werden disjunktiv, Bedingungen konjunktiv interpretiert. So kann gewünschte Information eindeutig charakterisiert werden.
- datalog-ähnliche Regeln  
Programm ist Menge von Patterns



## Lixto: Einfaches Beispiel

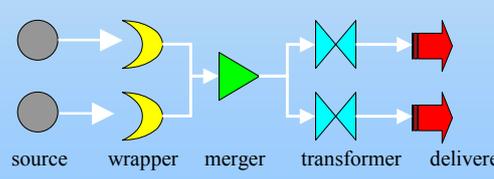
- Was ist der momentane Bestseller?
  - Einmal pro Woche abfragen
  - Ein Programmaufruf, einfache Programmerstellung
  - Programm soll weiter funktionieren trotz kleinerer struktureller Änderungen
  - Ziel: Automatisierung, Informationsweiterleitung (Handy, email, ...)
- 
- Tägliches Wetter
  - Rekursives Programm (eBay) verfolgen von Next Links
- Beispiele* ↩

# Now Playing!

- Extrahiert regelmäßig Daten von Radiostationen und Charts
- Verwendet Lixto und Infopipes Technologie
- In Zusammenarbeit mit T-Mobile




*Beispiel* ←



source wrapper merger transformer deliverer

# Einige Weblinks

- AgentWeb: <http://agents.umbc.edu/>
- Über Mobile Agenten: <http://www.infosys.tuwien.ac.at/Research/Agents/>
- MindIt: <http://minder.netmind.com/>
- Continual Queries: <http://www.cse.ogi.edu/DISC/CQ/>
- Ariadne (Knoblock et al.): <http://www.isi.edu/ariadne/>
- Florid: <http://www.informatik.uni-freiburg.de/%7Edbis/florid/online.html>
- JEDI: <http://www.darmstadt.gmd.de/oasys/projects/jedi/jedie.html>
- XWrap (Liu et al.): <http://www.cse.ogi.edu/DISC/XWRAP/>
- World Wide Web Wrapper Factory: <http://db.cis.upenn.edu/W4F/>
- Lixto: <http://www.dbai.tuwien.ac.at/proj/lixtto>



# Ausgewählte Literatur

---

## **Agenten allgemein:**

- Brenner, Zarnekow, Wittig: Intelligent Software Agents – Foundations and Applications
- Müller: The Design of Intelligent Agents – A Layered Approach

## **Theoretische Grundlagen:**

- Russell, Norvig: Artificial Intelligence – A Modern Approach

## **Internet-/Informationsagenten:**

- Caglayan, Harrison: Agent Sourcebook – A complete guide to Desktop, Internet and Intranet Agents
- Cheong: Internet Agents – Spiders, Webs, Brokers and Bots
- Klusch (ed.): Intelligent Information Agents

## **Semistrukturierte Daten:**

- Abiteboul, Buneman, Suciu: Data on the Web – From Relations to Semistructured Data and XML