

Infrastruktur für Web Intelligent Systems

**Thema: Business Intelligence –
Teil II: Data Mining & Knowledge Discovery**

von Christian Merker

Gliederung

- **Web-Intelligent-Systeme**
 - Begriffsklärung
 - Personalisiertes Web
 - Infrastruktur und Datenhaltung
- **Verfahren zur Ähnlichkeitssuche**
 - Algorithmen
 - Beispiele
- **Prefetching**
 - Begriffsklärung
 - Prefetching-Methoden
- **Zusammenfassung**

Web-Intelligent-Systeme

- Was ist Web-Intelligence ?
 - Es gibt eine Vielzahl von Definitionen, die sich in Aussage und Formulierung sehr unterscheiden.
 - Alle besitzen einen gemeinsamen Grundgedanken:

Daten über die Besucher von Internet-Seiten zu sammeln, um daraus auf die Interessen und Vorlieben des Besuchers zu schließen bzw. bei Benutzereingaben dieses Wissen zu verwenden.

Web-Intelligent-Systeme

- Was sind Web-Intelligent-Systeme ?
 - Web-Intelligent-Systeme sind Komponenten, die Algorithmen zur Ähnlichkeitssuche implementieren.
- Aufgaben:
 - Sammeln von Daten über die Benutzer,
 - Analyse der Daten,
 - Erstellung von Benutzerprofilen aus analysierten Daten,
 - Bereitstellung von Funktionalitäten für andere Systeme z. B. in E-Commerce-Systeme.

Web-Intelligent-Systeme

- Wie werden sie eingesetzt ?
- Einsatzgebiete:
 - **Portale**
 - Anpassung des Arbeitsbereichs an individuelle Bedürfnisse.
 - ➔ Schnellere Erreichbarkeit der gewünschten Informationen.
 - **Marketing-Instrument**
 - Verwendung von Wissen über Benutzervorlieben, um interessante Produkte anzubieten.
 - ➔ Personalisierte Werbung!

Personalisiertes Web

- Ziel: Möglichst viele persönliche Daten über den / die Benutzer sammeln!
- **Datenerhebung:**
 - **Bewertungsfragebogen**
 - Benutzer weiß, welche Daten er preisgibt.
 - **Digitale Fußspuren**
 - Besuchte Links auf einer Seite oder
 - Verweildauer auf Seite.
 - Benutzer weiß nicht welche Daten er preisgibt.

Personalisiertes Web

- Realisierung
 - **Cookies:**
 - Speicherung des Cookies auf Client-Seite,
 - Eindeutige Identifikation des Benutzers im System,
 - Auslesen der Daten im Cookie beim Seitenaufruf.
 - **Registrierung:**
 - Benutzer erhält Benutzernamen,
 - Eingabe persönlicher Vorlieben (Profil),
 - Dauerhafte Verwaltung der Benutzerdaten auf Server-Seite.

Personalisiertes Web


- Verwendung der Daten:
 - Persönliches ansprechen des Benutzers,
 - Gestaltung der Seite nach Benutzerwünschen.
(z. B. Benutzer erhält beim Anmelden im System alle Börsendaten, die er beim letzten Besuch betrachtet hat.)
- Schattenseiten:
 - Verkauf der Profile,
 - „Belästigung“ durch sog. Spam-Mails.

Infrastruktur und Datenhaltung

- Probleme:
 - Entstehen von großen Datenmengen durch Interaktion,
→ „Click-Stream-Daten“
 - Hoher Datendurchsatz erforderlich.
- Lösung:
 - Entfernen von Rauschen,
 - Analyse der Daten (Aggregation von Informationen),
 - Verwendung einer Speicherhierarchie:
 - Web-Server mit Datenbank,
 - Data-Warehouse und
 - Third-Level-Speicher.


Web-Server mit Datenbank

- Aufgaben:
 - Bereitstellen der Web-Seiten,
 - Haltung der aktuellsten Benutzerdaten,
 - Herausfiltern unnötiger Daten aus „Click-Stream“,
 - Speicherung der Daten für ~24 h,
 - Priorisierung auf Durchsatz.




Data-Warehouse

- Aufgaben:
 - Haltung der Daten mit **mittlerer** Zugriffswahrscheinlichkeit,
 - Analyse der Daten für Marktforschungen,
 - Speicherung der Daten bis zu 12 Monaten.



Third-Level-Speicher

- Aufgaben:
 - Haltung der Daten mit **geringer** Zugriffswahrscheinlichkeit,
 - Verwendung der Daten für Langzeitanalysen,
 - Speicherung über Jahre bzw. Jahrzehnte.



Gliederung

- **Web-Intelligent-Systeme**
 - Begriffsklärung
 - Personalisiertes Web
 - Infrastruktur und Datenhaltung
- **Verfahren zur Ähnlichkeitssuche**
 - Algorithmen
 - Beispiele
- **Prefetching**
 - Begriffsklärung
 - Prefetching-Methoden
- **Zusammenfassung**

Algorithmen

- Erzeugte „Click-Stream“-Daten bestehen fast ausschließlich aus Textdaten.
 - ➔ Verwendung von Methoden aus Text Retrieval!
- Einteilung der Algorithmen in 4 Klassen:
 - Kollaborative Filter,
 - Cluster-Verfahren,
 - Suchbasierte Verfahren,
 - Item-to-Item Collaborative Filtering.

Kollaborative Filter (1)

- Darstellung der Benutzerdaten als N-dim Vektor,
- Vektoreinträge enthalten positive / negative Produktbewertungen des Benutzer.

- Annahme für Ähnlichkeitssuche:
 - Ähnliche Benutzerinteressen werden durch ähnliche Produktbewertungen wiedergegeben.
 - ➔ Ähnlichkeitsvergleich der Benutzerbewertungen!

Kollaborative Filter (2)

- Bewertung:

- + Liefert sehr gute Ergebnisse!

- (Verwendung des Cosinus-Maß)

- Vergleich sehr teuer!

- (Benutzer muss mit allen im System vorhandenen Benutzer verglichen werden.)

- Nicht geeignet bei vielen Benutzern!

Cluster-Verfahren

- Verfahren ähnlich dem Kollaborativen Filtern.


Aber:

- Gruppierung von ähnlichen Benutzern zu Clustern.
- **Suche:**
 - Vergleich des Benutzers mit Repräsentanten jedes Clusters.
 - Suche nach ähnlichstem Benutzer im Cluster mit ähnlichsten Repräsentanten fortsetzen.

Cluster-Verfahren (Beispiel)

Vorbereitungsphase:


1. Wähle für jeden Cluster einen Repräsentanten (manuell).



Cluster-Verfahren (Beispiel)

Vorbereitungsphase:

1. Wähle für jeden Cluster einen Repräsentanten (manuell).
 2. Ordne restliche Benutzer dem ähnlichsten Repräsentanten zu.
- Cluster




Cluster-Verfahren (Beispiel)

Vorbereitungsphase:

1. Wähle für jeden Cluster einen Repräsentanten (manuell).
 2. Ordne restliche Benutzer dem ähnlichsten Repräsentanten zu.
- Cluster

Laufzeitphase:

1. Vergleiche aktuellen Benutzer mit Cluster-Repräsentanten.




Cluster-Verfahren (Beispiel)

Vorbereitungsphase:

1. Wähle für jeden Cluster einen Repräsentanten (manuell).
 2. Ordne restliche Benutzer dem ähnlichsten Repräsentanten zu.
- Cluster

Laufzeitphase:

1. Vergleiche aktuellen Benutzer mit Cluster-Repräsentanten.
2. Wähle den Cluster mit ähnlichstem Repräsentanten aus.




Cluster-Verfahren (Beispiel)

Vorbereitungsphase:

1. Wähle für jeden Cluster einen Repräsentanten (manuell).
 2. Ordne restliche Benutzer dem ähnlichsten Repräsentanten zu.
- Cluster

Laufzeitphase:

1. Vergleiche aktuellen Benutzer mit Cluster-Repräsentanten.
2. Wähle den Cluster mit ähnlichstem Repräsentanten aus.
3. Vergleiche aktuellen Benutzer mit allen Benutzern im gewählten Cluster.



Cluster-Verfahren

- Bewertung:

- + Berechnung der Cluster nicht zur Laufzeit!

- + Weniger Vergleiche notwendig!

- Qualität der Ergebnisse schlechter als bei Kollaborativen Filtern!

- Grund: Benutzerprofil kann in einen Cluster gelangen der nicht den ähnlichsten Benutzer enthält.

Suchbasierte Verfahren (1)

- Untersuchung der vom Benutzer gekauften Produkte,
- Suchanfrage mit Schlüsselworten aus den Produkteigenschaften,
(z. B. Autor, Darsteller, Genre ...)
- Suchanfrage kann einer SQL-Anfrage auf DB entsprechen.

Suchbasierte Verfahren (2)

- Bewertung:

- + Sehr gute Ergebnisse bei wenigen gekauften Produkten!

- Anfrageergebnis sehr groß, bei vielen gekauften Produkten und disjunktiver Verknüpfung der Schlüsselworte!

Item-to-Item Collaborative Filtering

- Weiterentwicklung des suchbasierten Verfahrens,
 - Matrix mit Ähnlichkeitswerten für jedes Produkt,
 - Matrixberechnung geschieht nicht zur Laufzeit.
-
- Zur Laufzeit: Für gekaufte Produkte des Benutzers die n-ähnlichsten Produkte aus entsprechenden Matrizen auswählen.

Item-to-Item Collaborative Filtering

- Beispiel

Ähnlichkeit zu Produkt X	
A	83%
B	70%
C	68%

↓
A

Ähnlichkeit zu Produkt Y	
D	81%
E	74%
B	66%

↓
D

Ähnlichkeit zu Produkt Z	
C	72%
F	47%
G	32%

Benutzer	Gekaufte Produkte	Interessante Produkte
Fritz Meier	X, Y	A, D

Item-to-Item Collaborative Filtering

- Bewertung:
 - + Verfahren ist zur Laufzeit sehr schnell!
 - + Liefert sehr gute Ergebnisse!
 - + Auch bei großen Produktkatalogen effizient!
(Anzahl Produkte >1.000.000)
 - Matrixberechnung sehr aufwändig und
speicherplatzintensiv!
 - **Aber:** Berechnung nicht zur Laufzeit!

Beispiele

- myFreddy.com (www.myFreddy.com)
 - Testplattform für Algorithmen,
 - Gegründet, um Testdaten zu gewinnen.

The screenshot shows a web browser window with a yellow header. The browser's address bar contains the URL "www.myfreddy.com". The page title is "Freddy". The main content area is divided into two columns. The left column features a meme of a character with a red helmet and a speech bubble that reads: "My doctor said I shouldn't expose myself to low scores and you aren't helping." Below this is another meme titled "you are the weakest link Good-Bye" with the text "Owner: Timmah", "140 votes (5.25)", and "You vote:3". A red circle highlights this section. The right column features a meme titled "being safe never looked better" with a photo of a mouse wearing a red helmet next to a mousetrap. Below the photo is the text "(Add yours) : (Send it to a friend)". At the top of the page, there is a navigation bar with dropdown menus for "Messages", "Personal", "Explorer", and "Funny pictures". A red box highlights a voting section that says "Here we vote >>" followed by a row of 10 radio buttons numbered 1 to 10.

Beispiele

- PalmAgent
 - Führungssystem für Touristen,
 - Basierend auf PDA's,
 - PDA besitzt Agent, der Benutzerinteressen kennt,
 - Neue Daten (z. B. Veranstaltungen) durch Funk oder durch automatischen Austausch mit anderen Agenten,
 - Bewertung der Informationen nach Benutzervorlieben durch den Agenten,
 - Ähnlich dem Nexus-Projekt.
(<http://www.nexus.uni-stuttgart.de/>)

Gliederung

- **Web-Intelligent-Systeme**
 - Begriffsklärung
 - Personalisiertes Web
 - Infrastruktur und Datenhaltung
- **Verfahren zur Ähnlichkeitssuche**
 - Algorithmen
 - Beispiele
- **Prefetching**
 - Begriffsklärung
 - Prefetching-Methoden
- **Zusammenfassung**

Prefetching

- Ziele:
 - Optimale Ausnutzung der Bandbreite zwischen Client und Server,
 - Wartezeit für den Benutzer verkürzen,
 - Reduzierung der Latenzzeit.
- Durchführungsmöglichkeiten:
 - Verhalten des Benutzers statistisch schätzen,
 - Zeitspanne zwischen 2 Aufrufen verwenden.

Prefetching

- Prefetching Methoden
 - Client-basiertes Prefetching,
 - Proxy-basiertes Prefetching,
 - Server-basiertes Prefetching,
 - Kooperatives Prefetching.

Client-basiertes Prefetching

- Analyse des Benutzerverhaltens.
 - ➔ Gewohnheiten des Benutzers sehr gut ableitbar!
- Unterteilung in 2 Klassen:
 - Greedy: Alle Links auf einer Seite werden vorgeladen.
 - ➔ viele unnötige Daten!
 - Non-Greedy: Aufrufhäufigkeiten werden berücksichtigt.
 - ➔ häufig besuchte Seiten als interessanter einstufen!

Proxy-basiertes Prefetching

- Proxy verwaltet normalerweise eine ganze Domäne.
 - ➔ Aufrufe von mehreren Benutzern sind bekannt.
- Aufrufreihenfolgen miteinander vergleichen.
 - ➔ Benutzerverhalten auf Seiten vorhersagbar.
- Vergleich neuer Aufrufe mit bekannten Aufrufreihenfolgen und Folgeseiten vorladen.
- Komprimierung der Daten, um Übertragungszeit zu sparen.

Server-basiertes Prefetching

- Server besitzt größere Historie als Proxy und Client.
- Wissen über das Verhalten vieler Benutzer.

- Zwei Strategien
 - Push
 - Übertragung der z. B. 10 am häufigsten angeforderten Seiten bei jeder Anfrage.
 - Pull
 - Übergabe einer Liste der häufigsten angeforderten Seiten,
 - Auswahl von „interessanten“ Seiten durch Proxy / Client,
 - Auswahl an Server melden.

Kooperatives Prefetching

- Prefetching auf allen Ebenen.
- Kombination der Vorteile der 3 Verfahren.
- Server können interessante Seiten an Proxy schicken.
- Proxy kann Interessen der Benutzer an Server schicken.
- Clients können Verlaufsdaten an Proxy schicken.
 - ➔ Hohe Kommunikation auf allen Ebenen.
 - ➔ Erweiterung um Web-Intelligent-Komponenten möglich.
 - ➔ **Web-Intelligent-System.**

Zusammenfassung

- Web-Intelligence
 - Begriff, Aufgaben, Einsatzgebiete (z. B. Portale),
 - Personalisiertes Web,
 - Infrastruktur (3-stufige Speicherhierarchie).
- Algorithmen zum Vergleich von Profilen
 - Kollaborative Filter,
 - Cluster-Verfahren,
 - Suchbasierte Verfahren,
 - Item-to-Item Collaborative Filtering.
- Prefetching
 - Client-, Proxy-, Server-basiertes Prefetching,
 - Kooperatives Prefetching.