

Web Data Mining

Albert Weichselbraun

Vienna University of Economics and Business
Department of Information Systems and Operations
Augasse 2-6, 1090 Vienna

`albert.weichselbraun@wu.ac.at`

May 2011

Agenda

Aufgabenstellung

Facebook

Web 2.0 Datenquellen

Administration

Technologie

Facebook Application

Web 2.0 Datenquellen

Geographische Visualisierungen

Aufgabenstellung

“Web Mining - Web Corpus Challenge”

1. soziale Quellen als Grundlage für sozialwissenschaftliche Forschung und
2. “Games with a Purpose” zur Erstellung und Evaluierung von derartigen Daten

Aufgabenstellung

Ziel dieses Projektes ist es

- ▶ Benutzerrezensionen (Rezension + Bewertung) aus dem Web zu extrahieren und diese in einer Datenbank zu speichern.
- ▶ Ein “Game with a Purpose” auf einer Social Networking Plattform (Facebook) zu erstellen, welches es dem Benutzer ermöglicht die Top Einflussfaktoren für das gewählte Rating zu identifizieren.
- ▶ Eine (minimale) Applikation zur Administration und Visualisierung der Ergebnisse zu erstellen (optional).

Arbeitspakete

- ▶ Komponenten zum Spiegeln von Bewertungsportalen (Amazon, Ciao, TripAdvisor, IMDB, RottenTomatoes, ...) und zum Extrahieren der relevanten Informationen
- ▶ Facebook “Game with a Purpose” zum Annotieren von Reviews
- ▶ Admin Applikation (optional)

Arbeitsaufteilung

Kernaspekte

- ▶ Technische Aspekte: Facebook-Applikation, Spider, Visualisierung, ...
- ▶ Organisatorische Aspekte: Zeitplan, Organisation von Treffen, Projektdokumentation, ...
- ▶ Strategische Aspekte: Planung, Modellierung, Marketing, Aufteilung der Workpackages, ...

Wöchentliches Reporting durch mindestens ein Gruppenmitglied

Achtung: Es wird erwartet, dass *jedes* Gruppenmitglied zumindest einen Programmiertask übernimmt.

Facebook - Anforderungen

- ▶ Design, Erstellen und Verteilen einer Facebook Applikation
- ▶ Originelle Spielidee
- ▶ Verhindern von Cheating
- ▶ Empfehlung: Verwendung von vordefinierten Kategorien für die Annotation oder Markieren von Ausdrücken im Text.
- ▶ Beispiel: apps.facebook.com/sentiment-quiz/

Integration von Web 2.0 Datenquellen

- ▶ Recherche: mögliche nützliche Datenquellen (TripAdvisor, Amazon, Ciao) & der entsprechenden Schnittstellen (API, ..)
- ▶ Wenn notwendig: Extraktion der relevanten Information aus dem Datenstrom
- ▶ Implementierung von ein bis zwei dieser Quellen und Integration der Quellen ins Datenschema
- ▶ Meta Informationen: Benutzer, Ort, Datum, ...

Administration

- ▶ Web Applikation zur Kontrolle der im Repository gespeicherten Daten
- ▶ Visualisierungen:
 - ▶ Anzahl der erfassten Rezensionen
 - ▶ Anzahl der von Benutzern annotierten Rezensionen
 - ▶ Geographische Verteilung der Benutzer

Facebook Application

Vorgangsweise:

- ▶ Facebook:

- ▶ Ausgangspunkt: www.facebook.com/developers/
- ▶ Neue Applikation erstellen
- ▶ Canvas
 - URL: www.facebook.com/sql_example/
 - Callback URL:
xmdimrill.ai.wu.ac.at/~aweichse/projects/2011s/sql2/GPa/

- ▶ xmdimrill:

- ▶ Example Code + Library auf Dimrill kopieren.
- ▶ Applikation mittels Canvas URL oder Canvas Callback URL testen.

Web 2.0 Datenquellen

Stand-alone Applikation (PHP, Python, Java)

- ▶ Technologie: anwendungsspezifisch
- ▶ Beginn: Recherche und entsprechende Dokumentation
- ▶ Integration von mindestens ein bis zwei externen Quellen
- ▶ Beachtung der Mirroring Restriktionen (zum Beispiel: maximal ein Request per Sekunde)
- ▶ Extraktion der Reviews: Reguläre Ausdrücke, DOM Tree (DOM Inspector, Firebug)

Web 2.0 Datenquellen - Beispiel: IMDB Review einlesen

```
1 <?php
2     // Beispiel: read Web page with the first
3     //           10 comments for the movie
4     //           tt0120794 (Prince of Egypt).
5     $url='http://www.imdb.com/title/tt0120794',
6         . '/usercomments';
7     $lines=file($url);
8     print_r($lines);
9 ?>
```

Geographische Visualisierungen



Geographische Visualisierungen

- ▶ Verwendung der Google MAPS API
- ▶ Vorgangsweise:
 - ▶ API Key Anfordern
 - ▶ KML File erstellen (dynamisch/statisch)
 - ▶ JavaScript Code in die Webseite integrieren und KML File angeben.
- ▶ Beispiel:
www.ai.wu.ac.at/~aweichse/projects/2011s/sql2/examples/maps/
(~aweichse/public_html/projects/2011s/sql2/examples/maps)

Geographische Visualisierungen

```
1  <?xml version="1.0" encoding="UTF-8"?>
3  <kml xmlns="http://earth.google.com/kml/2.1">
4  <Document>
5  <name>Example</name>
6  <description>An Example KML File</description>
8  <Placemark>
9    <name>Perth</name>
10   <description>An Example Placemark</description>
11   <Point><coordinates>
12     115.833297729,-31.9333000183
13   </coordinates></Point>
14 </Placemark>
15 </Document>
16 </kml>
```

Geographische Visualisierungen

```
1 <html xmlns="http://www.w3.org/1999/xhtml"><head>
3 <script
4 src="http://maps.google.com/maps?file=api&v=2&key=XXXX"
5 type="text/javascript"></script>
6 <script type="text/javascript">
7   function load() {
8     if (GBrowserIsCompatible()) {
9       var map = new GMap2(document.getElementById("map"));
10      var geoXml = new GGeoXml("http://t.at/myGeoFile.kml");
12      map.setCenter(new GLatLng(48.2,16.36), 3);
13      map.addControl(new GLargeMapControl());
14      map.addOverlay(geoXml);
15    }
16  }
17 </script>
19 </head>
20 <body onload="load()" onunload="GUnload()">
21   <div id="map" style="width: 680px; height: 400px"></div>
22 </body>
23 </html>
```