Web-Suche

Benutzer-Schnittstelle

Websuche: Benutzer-Schnittstelle

- Web-Suchmaschinen brauchen natürlich eine web-basierte Benutzer-Schnittstelle.
- Die Suchseite muss einen Anfragestring entgegennehmen und diesen mittels eines HTML-<form>ulars übertragen.
- Das Programm auf dem Server muss Anfragen verarbeiten und eine HTML-Seite für die am höchsten gelisteten Dokumente (mit Links zu den ursprünglichen und/oder zwischengespeicherten Webseiten) erzeugen.

Eingabeformulare

- HTML unterstützt verschiedene Arten der Programmeingabe in Formularen einschließlich:
  - Textbox
  - Menüs
  - Prüfbox
  - Auswahlbuttons
- Wenn ein Anwender ein Formular abschickt, werden Stringwerte für verschiedene *Parameter* zur Verarbeitung an den Server übertragen.
- Der Server nutzt diese Werte, um eine geeignete HTML-Antwortseite zu berechnen.

Ein einfaches Suchformular

```
<form action="http://titan.cs.utexas.edu:8082/servlet/irs.Search"
        method="POST">
<p>
<b> Gebe Anfrage ein: </b> <input type=“text" name=“Anfrage" size=40>
<p>
<b>Suchdatenbank: </b>
<select name=“Verzeichnis">
  <option selected value="/corpora/UniK/">
    Universität Kassel
  <option value="/corpora/KDE/">
    FG Wissensverarbeitung
</select>
<input type=“hidden" name=“Start" Wert="0">
<br>
<br>
<input type=“submit" value=“Anfrage ausführen">
<input type=“reset" value=“Formular zurücksetzen">
</form>
```

Web-Anwendungen

- Web-Anwendungen sind Anwendungen, die über das Web benutzt werden, d.h.
  - HTTP als Transportprotokoll
  - HTML als Benutzer-Schnittstelle.
- Verknüpfung von HTML und Businesslogik
  - dynamisch generierte HTML-Seiten
- Beispiele:
  - CGI-Skripte (Perl, Python, ...)
  - PHP
  - Content-Management-Systeme: Zope, Typo3, ...
  - Java Servlets

Webserver

- Dienst zur Auslieferung von Webseiten über das HTTP-Protokoll.
- Einfachste Variante:
  - statisches HTML im Dateisystem

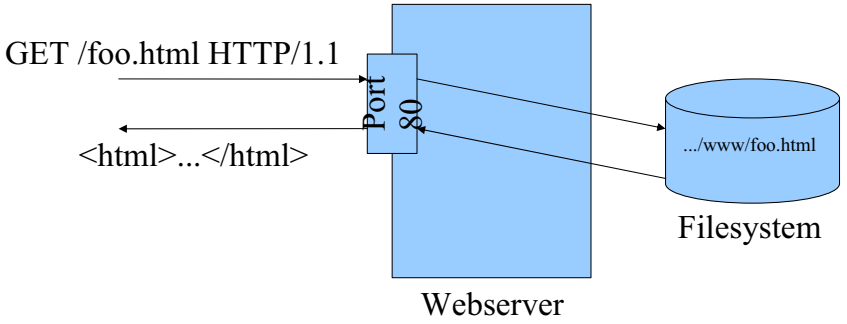

Web-Applikationsserver

- Webserver + Business-Logik
  - Reaktion auf Benutzereingaben
  - Datenbankzugriffe
- Mischen von HTML und Logik
  - Logik in HTML (vgl. PHP)
  - HTML wird von Programm erzeugt (vgl. CGI)
  - Mischformen
- beinhaltet oft weitere Dienste
  - Datenbankanbindung
  - Lastverteilung
  - Hochverfügbarkeit

Was ist ein Servlet?

- Javas Antwort auf CGI-Programmierung zur Verarbeitung von Webformular-Anfragen.
- Das Programm läuft auf Webservern und erzeugt dynamische/angepasste Seiten.
- Wann verwendet man Servlets?
  - Seite basiert auf vom Benutzer eingegebenen Daten, z.B. Suchmaschinen.
  - Daten ändern sich oft, z.B. Wetterberichte.
  - Seite verwendet Informationen von einer Datenbank, z.B. Online-Speicher.
- Erfordert das Betreiben eines Webservers, der Servlets unterstützt.

Servlet-Container

- Webserver, der Servlets beheimatet
  - übernimmt Netzwerkverkehr
  - bietet Infrastruktur
    - Konfiguration, Skalierbarkeit, ...

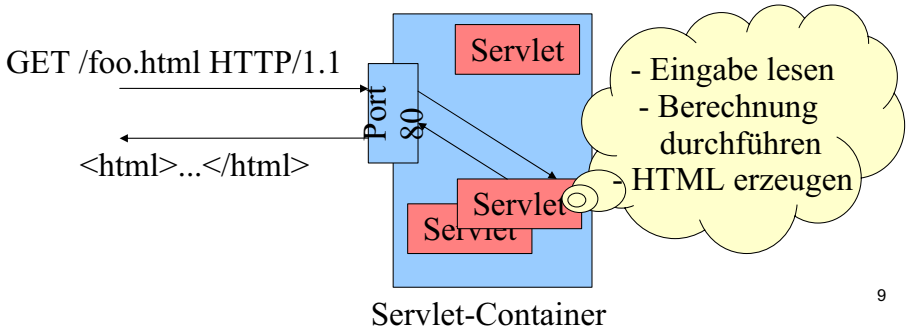

Formularbeispiele

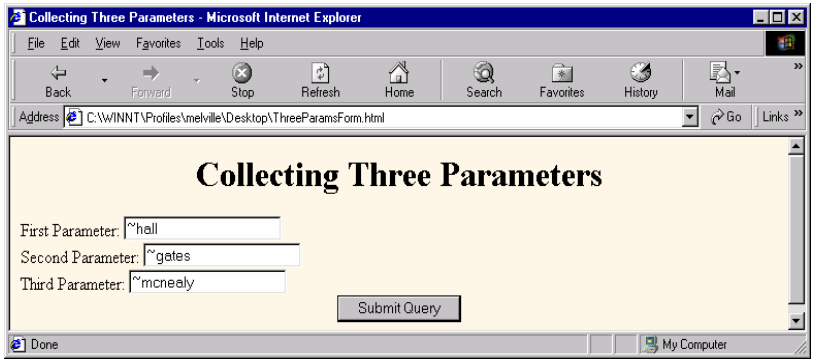

Servlet Ausgabe

HTML-Post-Form

```
<FORM ACTION="/servlet/hall.ThreeParams"
      METHOD="POST">
  First Parameter:  <INPUT TYPE="TEXT"
  NAME="param1"><BR>
  Second Parameter: <INPUT TYPE="TEXT"
  NAME="param2"><BR>
  Third Parameter:  <INPUT TYPE="TEXT"
  NAME="param3"><BR>
  <CENTER>
    <INPUT TYPE="SUBMIT">
  </CENTER>
</FORM>
```

Reading Parameters

```
public class ThreeParams extends HttpServlet {
 public void doGet(HttpServletRequest request,
   HttpServletResponse response) throws ServletException,
   IOException {
   response.setContentType("text/html");
   PrintWriter out = response.getWriter();
   out.println(… +"<UL>\n" +
    "<LI>param1: " + request.getParameter("param1") + "\n" +
    "<LI>param2: " + request.getParameter("param2") + "\n" +
    "<LI>param3: " + request.getParameter("param3") + "\n" +
    "</UL>\n" + …);
}
public void doPost(HttpServletRequest request,
   HttpServletResponse response) throws ServletException,
   IOException {
       doGet(request, response);
   }
}
```


Grundsätzliche Servlet-Struktur

```
import java.io.*;
import javax.servlet.*;
import javax.servlet.http.*;

public class SomeServlet extends HttpServlet {
  // Handle get request
 public void doGet(HttpServletRequest request, HttpServletResponse
   response) throws ServletException, IOException {
  // request – access incoming HTTP headers and HTML form data
  // response - specify the HTTP response line and headers
  // (e.g. specifying the content type, setting cookies).
  PrintWriter out = response.getWriter(); //out - send content to
   browser
 }
}
```


Lesen aller Parameter

- Liste aller Parameternamen, die Werte haben:

```
Enumeration paramNames = request.getParameterNames();
```

  – Parameternamen in unspezifizierter Reihenfolge.

- Parameter können viele Werte haben:

```
String[] paramVals =
request.getParameterValues(paramName);
```

  – Aufstellung von Parameterwerten, die mit *paramName* verbunden sind.

Einfaches Such-Servlet

- Basiert auf dem Parameter „Verzeichnis“ und erzeugt oder wählt einen vorhandenen InvertedIndex für den entsprechenden Korpus aus.
- Verarbeitet die Anfrage mit KSM, um eine gerankte Ergebnismenge zu ermitteln.
- Gibt in HTML eine geordnete Liste von 10 Ergebnissen aus, beginnend mit der Rangstelle des start parameters.
- Jede Position enthält:
  - Ursprüngliche Basis-URL, die vom Spider am Anfang des Dokuments im BASE-Tag gespeichert wurde.
  - Seiten-<TITLE>, der aus der Datei extrahiert wurde.
  - Zusätzlicher Verweis zur lokal zwischengespeicherten Datei.
- Erstellt ein Formular, um “Weitere Ergebnisse” beginnend mit der nächsten gelisteten Position anfordern zu können, falls noch nicht alle Ergebnisse angezeigt wurden.

Schnittstellenverbesserungen für die einfache Suche

- Verarbeitet gegenwärtig die Anfragen erneut, auch wenn nach "Weitere Ergebnisse" gefragt wird.
  - Könnte die gegenwärtig gerankte Liste zusammen mit der Anwendersitzung speichern.
- Könnte weitere Interaktionen durch Relevance Feedback integrieren.
- Könnte Anfrage: "Bestimme ähnliche Seiten" für jedes gefundene Dokument (wie in Google) liefern.
  - Verwende einfach gegebenen Dokumententext als eine Anfrage.

Andere Verbesserungen der Suchschnittstelle

- Hebe Suchbedingungen in dem angezeigten Dokument hervor.
  - Wie bei gecachter Datei in Google.
- ermögliche "erweiterte" Suche:
  - Phrasensuche (".")
  - Verbindliche Terme (+)
  - Negierte Terme (-)
  - Sprachpräferenzen
  - Rückwärts-Link
  - Datenpräferenzen
- Maschinelle Übersetzung von Seiten.

Andere Verbesserungen der Suchschnittstelle

- Gruppensuchergebnisse in kohärenten "Clustern":
  - "Mikrowelle"
    - Eine Gruppe über Ernähungsrezepte und Küchengeschirr.
    - Eine andere Gruppe über den Empfang von Satellitenfernsehen.
  - "Huskies"
    - Eine Gruppe über Hunde.
    - Eine Gruppe über das Kasseler Eishockey-Team.
- Northern Light gruppiert Ergebnisse in "Ordern", die auf einer voretablierten Kategorisierung von Seiten basieren (wie Yahoo- oder DMOZ-Kategorien).
- Eine Alternative ist, Suchergebnisse dynamisch in Gruppen ähnlicher Dokumente zusammenzufassen.

Meta-Suchmaschinen

- Suchmaschine, die eine Anfrage an einige andere Suchmaschinen weitergibt und die Ergebnisse integriert.
  - Unterbreite Anfrage an verschiedene Hostsites.
  - Parse die resultierenden HTML-Seiten, um dieSuchergebnisse zu extrahieren.
  - Integriere die unterschiedlichen Klassifizierungen in einer "Konsens"-Klassifikation.
  - Präsentiere dem Anwender das integrierte Ergebnis.
- Beispiele:
  - Metacrawler
  - SavvySearch
  - Dogpile

Anwenderverhalten

- Anwender neigen dazu, kurze Anfragen einzugeben.
  - Eine Studie in 1998 ergab eine Durchschnittslänge von 2.35 Worten.
- Anwender neigen dazu, keine erweiterten Suchoptionen zu verwenden.
- Anwender müssen bei der Verwendung komplexerer Anfragen eingewiesen werden.