Vorlesung Netzbasierte Informationssysteme (WS 2004/05) Suchmaschinen

Robert Tolksdorf
Freie Universität Berlin
Institut für Informatik
Netzbasierte Informationssysteme
mailto:tolk@inf.fu-berlin.de
http://www.robert-tolksdorf.de
http://nbi.inf.fu-berlin.de

Überblick

Überblick

- Server- und Klientenseitige Verarbeitung
- Caching im Web

Server- und Klientenseitige Verarbeitung Überblick

Überblick

- Statische und Dynamische Inhalte
- Serverseitige dynamische Inhalte
- Klientenseitige dynamische Inhalte

Dynamische Web Seiten

- Seiten können
  - *Statische Inhalte* liegen vorgefertigt auf dem Server und werden unverändert ausgeliefert und dargestellt
  - *Dynamische Inhalte* bewirken vor und bei der Auslieferung oder der Darstellung Effekte auf Inhalt oder Darstellung durch Ausführung von Programmen
- Aufgaben
  - Serverseitig
    - Vereinfachung der Inhaltserstellung (SSI)
    - Erzeugung/Konvertierung von Inhalt
    - Anpassung/Personalisierung von Inhalt
    - Ergebnis anderer serverseitiger Transaktionen
  - Clientenseitig
    - Erzeugung einer Darstellung
    - Anpassung von Darstellung
    - GUI Interaktion mit Nutzer

Serverseitige Verarbeitung

- Templatesprachen
  - SSI, PHP,…
  - Ähnl. SSI Anweisungen in HTML eingestreut, mächtigere Sprache
- CGI/Skriptsprachen
  - /bin/sh, Perl, Phython,…
  - Imperativer Programmcode, oft mit Stärken in Stringverarbeitung
- CGI/Reguläre Programme
  - Binaries in beliebiger Programmiersprache
  - Geschwindigkeit
- Sprache/API in Server eingebunden
  - Servererweiterungen (NSAPI, ISAPI, Apache), Servlets/JSP, ASP,
  - Kein externer Interpreter sondern Teil des Servers

Server Side Includes

- Server Side Includes (SSI) sind Anweisungen an den Web Server, die im HTML Code eingebunden sind
- Werden vom Server bei Auslieferung ausgeführt und zu HTML Code expandiert
- SSI Anweisung im statischen HTML-Code:

```
<div align="right">
 Letzte &Auml;nderung: <!--#flastmod file=""-->.
</div>
```

- Ergebnis nach Auslieferung

```
<div align="right">
Letzte &Auml;nderung: Wednesday, 08-Jan-2003
09:30:15 CET.
</div>
```

SSI Anweisungen

- Als HTML-Kommentar eingebettet:
  `<!--#direktive Attribut1="Wert1„ Attribut2="Wert2"…-->`
- Direktiven:
  - `flastmod`: Fügt Änderungsdatum der im Attribut `file` genannten Datei ein
  - `fsize`: Fügt Größe der im Attribut `file` genannten Datei ein
  - `include`: Fügt Datei ein. Bezeichnung je nach Attribut:
    - `virtual`: Pfad im Web-Verzeichnisbaum
      ```
      <!--#include virtual="/inst/ag-nbi/include/nbiheader" -
      ->
      ```
    - `file`: Pfad im (nur „unter" aktueller Datei)
  - `exec`: Führt Kommando oder
    - `cgi`: Pfad im Web-Verzeichnisbaum (Apache 2.0: `include virtual`)
    - `cmd`: Ausführung im Datei-Verzeichnisbaum
      ```
      <pre>
      <!--#exec cmd="/usr/bin/ls -l"-->
      </pre>
      ```


SSI

- `echo`: Gibt Inhalt der im Attribut `var` bezeichneten Variablen aus
- SSI-Variablen
  - `DOCUMENT_NAME`: Dateiname des Dokuments im Datei-Verzeichnisbaum
  - `DOCUMENT_URI`: Dateiname des Dokuments im Web-Verzeichnisbaum
  - `QUERY_STRING_UNESCAPED`: Suchanfrage
  - `DATE_LOCAL`: Aktuelles lokales Datum
  - `DATE_GMT`: Aktuelles lokales Datum als GMT
  - `LAST_MODIFIED`: Veränderungsdatum
- Beispiel:
  ```
  Hier ist es <!--#echo var="DATE_LOCAL"-->.
  ```


SSI

- CGI-Variablen

SERVER_SOFTWARE	SERVER_NAME	
GATEWAY_INTERFACE		
SERVER_PROTOCOL	SERVER_PORT	REQUEST_METHOD
PATH_INFO	PATH_TRANSLATED	SCRIPT_NAME
QUERY_STRING	REMOTE_HOST	REMOTE_ADDR
AUTH_TYPE	REMOTE_USER	REMOTE_IDENT
CONTENT_TYPE	CONTENT_LENGTH	

- HTTP-Header der Form `HTTP_`*`Headername`*:
  - HTTP_ACCEPT, HTTP_USER_AGENT, …
- Beispiel:
  ```
  Wie geht es Ihnen bei
  <!--#echo var="REMOTE_ADDR"--> mit Ihrem
  <!--#echo var="HTTP_USER_AGENT"-->?
  ```


SSI

- set: Setzt den Inhalt der im Attribut `var` bezeichneten Variablen auf den im Attribut `value` angegebenen Wert
- Einfachste Ausdrücke bildbar

```
<!--#set var="salutation" value="Guten
Tag"-->
<!--#set var="remote"
  value="${REMOTE_ADDR} (${REMOTE_HOST})"--
>

<!--#echo var="salutation"--> at
<!--#echo var="remote"-->!
```

SSI

- Bedingte Abschnitte

```
<!--#if expr="Bedingung" -->
<!--#elif expr="Bedingung" -->
<!--#else -->
<!--#endif -->
```

- Bedingungen und Ausdrücke
  - String
  - $String_1$!= $String_2$
  - $String_1$ < $String_2$
  - $String_1$ <= $String_2$
  - $String_1$ > $String_2$
  - $String_1$ >= $String_2$
  - (Bedingung)
  - ! Bedingung
  - $Bedingung_1$ && $Bedingung_2$
  - $Bedingung_1$ || $Bedingung_2$

CGI

- CGI ist eine Schnittstelle zwischen Web-Server und Programm
  - URL bezeichnet CGI-Programm
  - Server startet Programm als Prozess
  - Server übergibt Parameter der Anfrage und anderes in Umgebungsvariablen
  - Programm verarbeitet Anfrage
  - Kann Seiteneffekte haben, teilweise sehr große
  - Programm erzeugt eine HTTP-Antwort (mit HTML-Seite oder anderem)
  - Server leitet Antwort an Klienten weiter
- CGI-Programm ist etwas Ausführbares
  - Interpreter (der Skript interpretiert)
  - Compiliertes Programm

Im Überblick

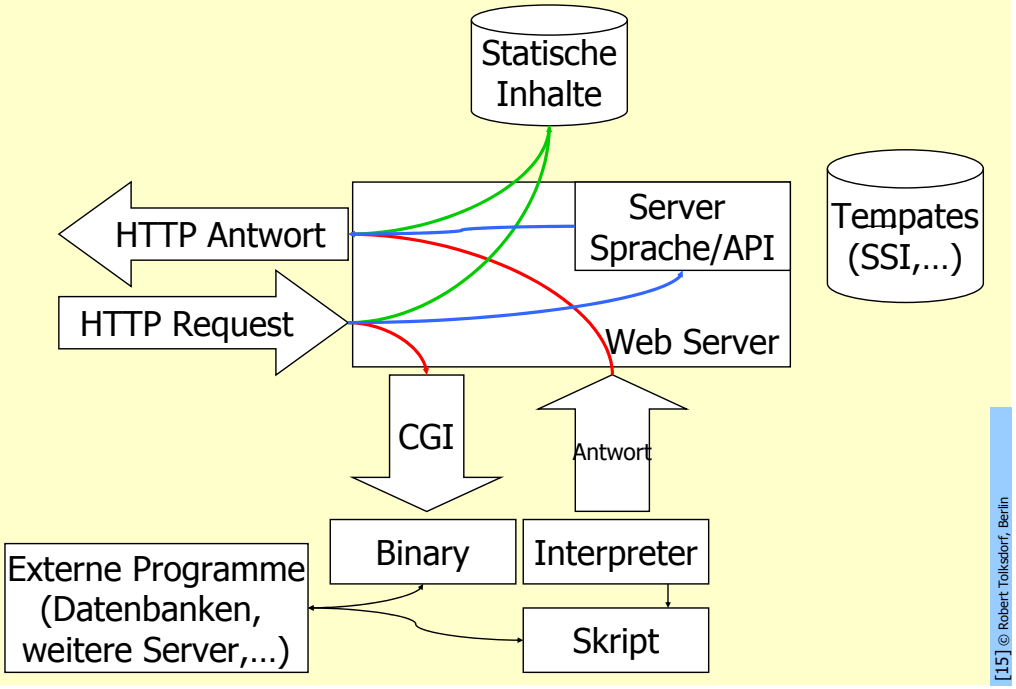

Klientenseitige Verarbeitung

- Vom Server gelieferte Seiten enthalten Dinge, die beim Klienten Ausführung bewirken
  - In Seiten referenzierte Objekte
    - andere Medienarten als HTML
    - Applets
  - Programme
    - Eingebettete Scripte

Referenzierte Objekte

- Browser verstehen bestimmte Medienarten
  - `text/html`
  - `image/jpg`
  - …
- Bei unbekannten Medienarten wie `application/x-shockwave-flash` oder `application/pdf` kann
  - gespeichert werden
  - durch Plugin ausgeführt werden
- *Plugin*
  - Browsererweiterung
  - Klientenseitig compiliert und vorinstalliert
  - Herstellerabhängig / Browserabhängig / Plattformabhängig
  - wird als Teil des Klientenprozesses ausgeführt
  - kann Verbindungen aufbauen

Referenzierte Objekte

- *Applets*
  - enthalten Programmcode und werden nicht dargestellt sondern ausgeführt
  - Ausführungsbasis ist nicht der Prozessor des Rechners sondern eine Java Virtual Machine, die direkt oder als Plugin im Browser installiert ist
  - Serverseitig compiliert und vorgehalten
  - Herstellerunabhängig / Browserunabhängig / Plattformunabhängig (?)
  - werden als Teil des Klientenprozesses in der JVM ausgeführt
  - können (konfigurierbar) eingeschränkt Verbindungen aufbauen
  - laden Programmcode nach
- *ActiveX*
  - ähnlich, aber Browser- und Plattformabhängig

Eingebettete (oder referenzierte) Skripte

- *Skripte*
  - Per <script> Tag eingebetteter oder referenzierter Programmcode
  - enthalten Programmcodequelltext und werden nicht dargestellt sondern ausgeführt bei Eintreffen von Ereignissen
  - Ausführungsbasis ist nicht der Prozessor des Rechners sondern ein Skriptinterpreter der direkt oder als Plugin im Browser installiert ist
  - Skriptsprachen sind einfache imperative Sprachen
  - Skripte werden serverseitig vorgehalten
  - Herstellerunabhängig / Browserabhängig / Plattformunabhängig (?)
  - Haben Zugriff auf Browserkontext (z.B. DOM des aktuellen Dokuments), unterschiedlich auf Rechner und Netz
  - JavaScript, ECMAScript, JScript, weitere…

Im Überblick

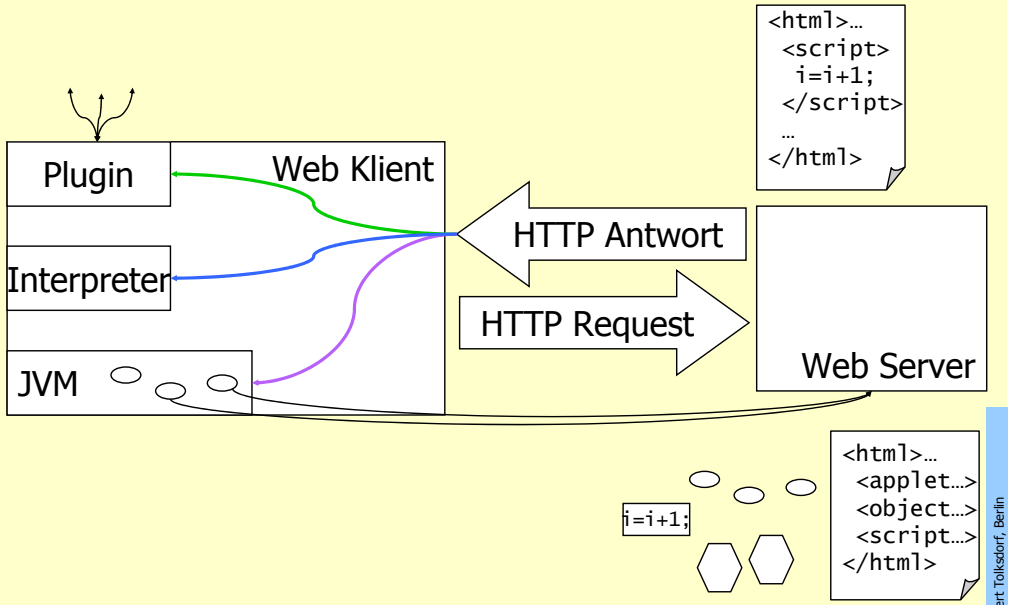

Zusammenfassung

- Dynamische Seiten
  - Serverseitig
    - Templates (SSI)
    - CGI
    - Servererweiterungen
  - Klientenseitig
    - Plugins / Medientypen
    - Applets etc.
    - Skripte

Literatur

- NCSA HTTPd Development Team. *Server Side Includes (SSI)*. http://hoohoo.ncsa.uiuc.edu/docs/tutorials/includes.html
- Apache HTTP Server Documentation Project. *Apache Tutorial: Introduction to Server Side Includes*. http://httpd.apache.org/docs/howto/ssi.html http://httpd.apache.org/docs-2.0/howto/ssi.html
- Sun Microsystems, Inc. *JavaServer Pages.* http://java.sun.com/products/jsp/
- Netscape Communications Corporation. *Plug-in Guide*. http://developer.netscape.com/docs/manuals/communicator/plugin/index.htm

Caching im Web

Überblick

- Caches
- Caching Architekturen
- Cache Füllung
- Cache Ersetzung
- Cache Kohärenz

Caching

- Ursprünglich aus Rechnerarchitektur:
  - CPU schneller als Hauptspeicher
  - ➔ Daten in schnellem Zwischenspeicher, dem *Cache* halten
- Ziel im Web: Netzwerklatenz kaschieren
  - Klient schneller als Netz (+Server)
- Grundbegriffe:
  - Gesuchte Daten zwischengespeichert vorgefunden: *Hit / Treffer*
  - Gesuchte Daten nicht gefunden: *Miss / Fault / Fehler*
  - Bei Fehler nachgeladenes Originaldatum in Cache gespeichert
  - ➔ Annahme: Mehrere Zugriffe zeitlich gruppiert
  - Oft: Block um gesuchte Daten in Cache geholt
  - ➔ Annahme: Zugriffe örtlich gruppiert

Proxies und Caching

- *Proxy/Stellvertreter* anstelle vom Klienten
  - Leitet HTTP Anfrage von Klienten an Server andere Proxies weiter
  - Tritt für den Server als Klient auf
  - Leitet Antwort an Klienten weiter
- *Proxy Cache*
  - Agiert auch als Cache
  - ➔ Annahme: Zugriffe organisatorisch gruppiert

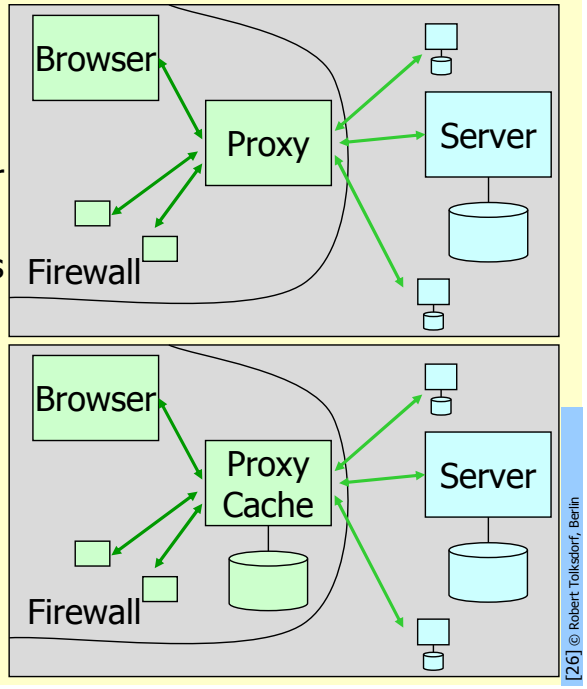

Vorteile

- Vorteile von (Proxy-)Caching
  - Netzlast kann effektiv gesenkt werden
  - Netzlatenz für Nutzer sinkt
    - Übertragungszeit sinkt, wenn Objekte im (netztopologisch) nahen Cache gefunden werden
    - Nicht gefundene Objekte werden schneller geholt wegen
      - geringere Netzlast auf dem Weg zum Server
      - geringere Last beim Server
    - "eight second rule": Web Seite muss innerhalb von 8 Sekunden angezeigt werden oder Nutzer verlieren Interesse an Site (bzw. Kauf…)
  - Serverlast sinkt wegen geringerer Zugriffszahl
  - Verfügbarkeit von Objekten steigt
  - Proxies lassen Nutzungsanalysen zu

Nachteile

- Nachteile von (Proxy-)Caching
  - Cache-Inhalt muss nicht konsistent mit Originaldaten sein
  - Bei einem Cache-Fehler steigt die Netzlatenz (➔ Hit-Rate maximieren, Miss-Kosten minimieren)
  - Proxy wird zum Engpass für Klienten
  - Proxy wird zum Single-point-of-failure
  - Proxy-Cache senkt Hit-Raten (und anderen Maße) beim Server (➔ Server können versuchen, Caching zu verhindern)
  - Unnötig bei Seiten die nur einmalig geladen werden

Notwendigkeit

- Netznutzung verursacht immer Kosten
- Netzlatenzen werden immer schwanken
- Entfernungen im Netz werden durch mehr Geräte größer
- Bandbreite der Inhalte wird immer steigen
- Populäre Server sind immer überlastet
- Netzkosten sind größer als Rechenkosten

Browser Konfiguration

- Browser kann zu externem Proxy-Cache gerichtet werden

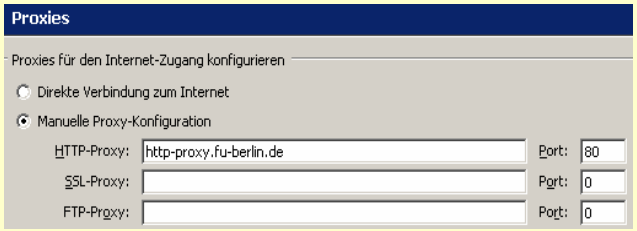

- Browser hat aber auch selber schon einen lokalen Cache (Speicher / Disk)

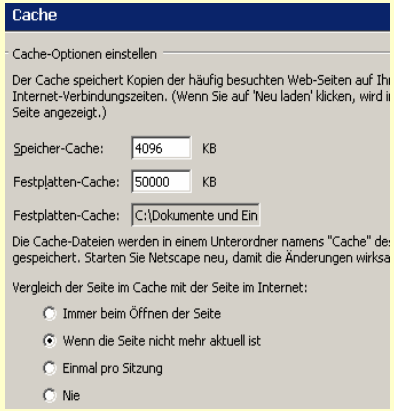

Caches im Web allgemein

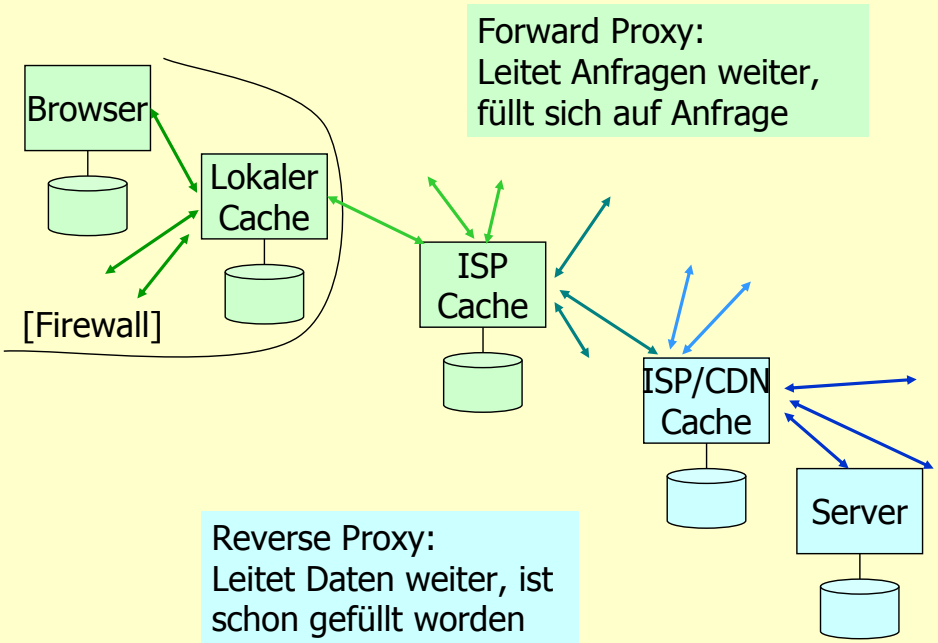

Caches

- Forward Proxy Caches
  - Stellvertreter für Klienten
  - Vermeidung der Netznutzung
  - Browser-Cache: Lokal, nutzerspezifisch
  - Proxy-Cache: Organisationsweit, gruppenspezifisch
  - ISP-Cache: Teilnetzweit
- Reverse Proxy Caches („HTTP Accelerators“)
  - Stellvertreter für Server
  - Vermeidung der Servernutzung
  - Content Delivery Network-Cache: Anbieterweit, sitespezifisch
  - Server Cache: Serverweit, sitespezifisch

Design-Ziele

- *Senkung der Netzlatenz* für Nutzer
- *Robustheit* gegenüber Fehlern
  - Toleranz zu einzelnen Ausfällen
  - Kontrollierter Leistungsrückgang
  - Einfaches Wiederherstellung nach Ausfällen
- *Transparenz* des Cachings für den Nutzer
- *Skalierbarkeit* mit Web-Wachstum
- *Effizienz* der Ressourcennutzung
  - Minimale zusätzliche Netzlast
  - Erhaltung optimaler Ausnutzung von Ressourcen
- *Adaptivität* zum Nutzerverhalten und Netzzustand
- *Stabilitätserhaltung* der Gesamtnetzes
- *Lastverteilung* entlang den beteiligten Komponenten
- *Einfachheit* als Voraussetzung weiter Verbreitung

Cache Architekturen - Hierarchisches Caching

- Hierarchisches Caching: Anfrage wird bei einem Cache-Miss über mehrere Hierarchiestufen weitergereicht

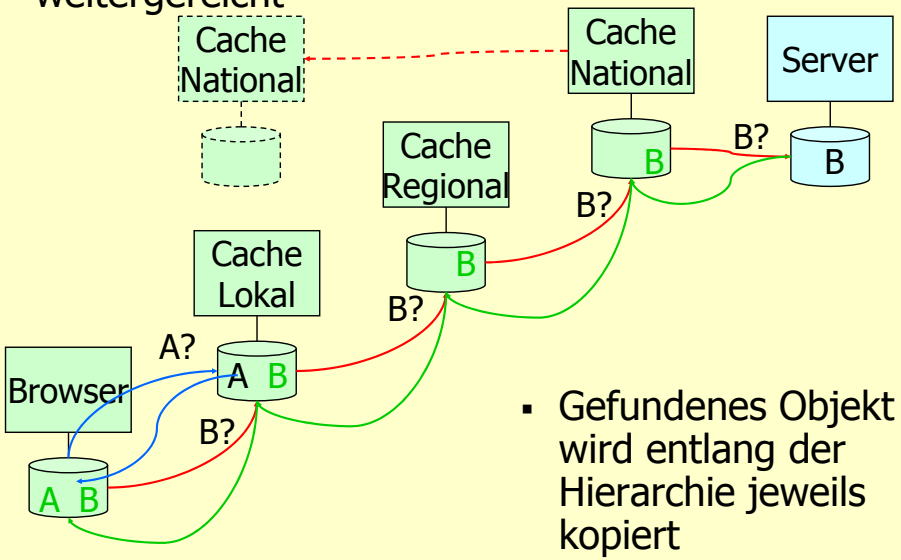

- Gefundenes Objekt wird entlang der Hierarchie jeweils kopiert

Cache Architekturen - Hierarchisches Caching

- Vorteile
  - In der Hierarchie niedrig stehende Caches profitieren von besserer Bandbreite der hoch stehende Caches
  - Daten werden in Richtung der Nachfrage repliziert
  - Senkt Latenz für kleine Dokumente relativ mehr
- Nachteile
  - Platzierung der Caches an zentralen Netzknoten ist kritisch
  - Je Cache-Level erneut zusätzliche Latenz möglich
  - Je höher ein Cache in der Hierarchie steht umso eher wird er zum Engpass
  - Daten werden an sehr vielen Stellen entlang der Cache-Hierarchie in Kopien gehalten

Cache Architekturen - Verteiltes Caching

- Caches kooperieren
  - wissen, welcher Cache welche Objekt hält (Tabelle, Hashing,…)
  - fragen nach (➔ Harvest ICP)
  - Ältere Forschungsprototypen, nicht verbreitet

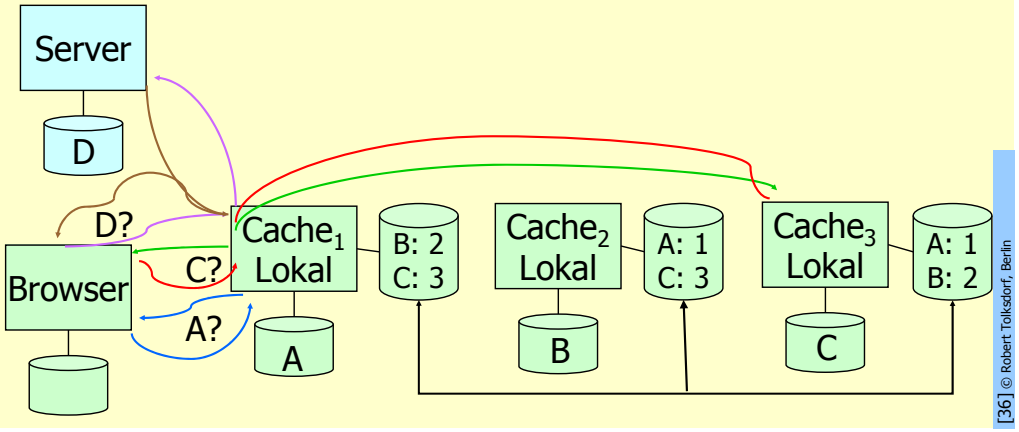

Cache Füllung

- Caches kommen auf Hit-Raten von 40-50%
  ➔ Wahrscheinliche Zugriffe vorwegnehmen
- Cache wird gefüllt durch
  - Kopieren nachgefragter Objekte
  - Aktives holen benachbarter Objekte
    - „Nachbarschaft" ergibt sich aus Einbettung von Objekten auf Web-Seiten und Links
    - Aktives Füllen eines Web-Caches: *Prefetching*

Prefetching

- Auswirkung
  - zwischen Browser und Server
    - 45% weniger Latenz beim Browser
    - 200% Netzlast
  - zwischen Proxy und Server
    - 60% weniger Latenz beim Browser
  - zwischen Klient und Proxy
    - 23% Weniger Latenz
    - Großer Browser-Cache notwendig
- Push-Ansätze
  - Server/Proxy verteilt Dokumente zu Klienten
  - nicht im HTTP Modell
- Prefetching nicht verbreitet / nicht als sinnvoll angesehen

Cache Ersetzung (Placement/Replacement)

- Wenn Cache voll ist, muss Platz durch Löschung von Objekten geschaffen werden
- Drei Ansätze
  - Traditionelle Ansätze, basiert auf Objektnutzung
    - Least Recent Used LRU:
      Objekt mit ältester Nachfrage wird gelöscht
    - Least Frequently Used LFU:
      Objekt mit wenigsten Nachfragen wird gelöscht
    - Pitkow/Recker:
      Wie LRU, aber: falls alle Objekte am selben Tag nachgefragt wurden, wird größtes gelöscht

Cache Ersetzung (Placement/Replacement)

- Basiert auf Ordnung von Objekteigenschaften
  - Size:
    Größtes Objekt wird gelöscht
  - LRU-MIN:
    Wendet LRU auf Objekte größer als s an, falls nur kleinere Objekte, LRU auf Objekte größer als s/2 anwenden usw.
  - LRU-Threshold:
    Wie LRU, aber Objekte über einer Größe s werden nicht zwischengespeichert
  - Hyper-G:
    Wie LFU, aber gleicher Rang über LRU und Size aufgelöst
  - Lowest-Latency-First:
    Objekt mit geringster Ladedauer wird gelöscht

Cache Ersetzung (Placement/Replacement)

- Basiert auf Nutzungskosten
  - GreedyDual-Size:
    Kosten werden mit Objekt verbunden, Objekt mit geringstem Kosten/Größe Verhältnis wird gelöscht
  - Lowest Relative Value:
    Nutzen wird mit Objekt verbunden, Objekt mit geringstem Nutzen wird gelöscht
  - Least Normalized Cost Replacement:
    Funktion Zugriffshäufigkeit × Übertragungskosten × Größe
  - …
- Performanz der Ersetzung ist stark von Nutzungscharakteristik abhängig
- Kein Verfahren ist für alle Nutzungscharakteristika am überlegen

Cache Kohärenz

- Nutzer können veraltete Seiten vom einem Cache erhalten
- Ähnlich Cache-Kohärenz in Verteilten Systemen, aber
  - andere Zugriffsmuster
  - andere Dimensionen
  - Web-Objekte werden nur an einem Ort geändert
- HTTP Unterstützung
  - Header `Expires:` *Datum* liefert Ungültigkeitsdatum
  - GET mit `If-Modified-Since:` *Datum* Header liefert Seite nur bei Änderungen nach einem Datum
  - Header `Pragma: no-cache` verhindert Caching
  - Header `Last-Modified:` *Datum* liefert Änderungsdatum
  - Header `Date:` *Datum* enthält Datum des letzten Tests auf Aktualität
  - Header `ETag:` *Signatur* liefert eine Quersumme des Objekts

Cache Kohärenz Mechanismen

- Starke Cache-Konsistenz: Immer aktuelle Objekte halten
  - Klient validiert
    - Annahme: Ressource im Cache sind veraltet
    - Vorgehen: Bei jeder Nutzung validieren
    - Implementierung: GET mit If-Modified-Since: Header
      - 200 – Keine Änderung
      - 304 – Not modified Antwort bei keiner Änderung (RFC: „should")
  - Server invalidiert
    - Annahme: Ressourcen im Cache sind aktuell
    - Vorgehen: Server sendet Mitteilung bei Änderung
    - Implementierung: Listen über Cache-Klienten führen
      - Wie skalieren?
      - Wie Listen aktuell halten?

Cache Kohärenz Mechanismen

- Schwache Cache-Konsistenz: Irgendwann aktuelle Objekte
  - Klient invalidiert: Adaptive Time-To-Live (TTL)
    - Ausgangspunkt: Lebensdauer von Objekten ist bimodal
      - Entweder sehr kurze Lebensdauer
      - oder sehr lange Lebensdauer
    - Vorgehen: TTL eines Objekts = Anteil seines Alters (Aktuelle Zeit – Last-Modified)
    - Implementierung: Harvest: Anteil = 50% (CERN httpd 10%)
    - Vorteil: Hält Anteil alter Dokumente unter 5%
    - Nachteile
      - Nur Heuristik: Nutzer muss eventuell unnötig warten
      - Nur Heuristik: Keine Aussage über tatsächliche Gültigkeit
      - Nutzer können Heuristik nicht beeinflussen
      - Was passiert bei abgebrochenen Ladevorgängen?

Cache Kohärenz Mechanismen

- Piggyback Invalidation (Piggyback = „Huckpack“)
  - Ausgangspunkt: Kommunikation mit Server nutzen um Gültigkeit zu erfragen
  - Vorgehen:
    - Piggyback Cache Validation (PCV):
      Mit einer Anfrage schickt Proxy ein Liste zu validierender Objekte
    - Piggyback Server Invalidation (PSI):
      Mit einer Antwort schickt Server eine Liste geänderter Objekte
    - Hybrid: PCV+PSI
      - Wenn letzter Kontakt lange her: PCV (Overhead bei langer PSI-Liste grösser)
      - Wenn letzter Kontakt kurz her: PSI (Liste kurz)

Cache-Fähigkeit von Objekten

- Statischer Inhalt von Seiten sehr gut zwischenspeicherbar
  - „sehr statische“ Inhalte (Logos) mit sehr spätem Expires Header
- Dynamische Inhalte schlecht zwischenspeicherbar
  - „sehr dynamisch“ Inhalte (Börsendaten) nicht cachen
  - „wenig dynamische“ Inhalte (Nutzeranschrift) kurz cachen
  - Serverseitiges Cachen als Alternative

Zusammenfassung

- Caches zur Latenzverkürzung beim Nutzer
- Mehrstufiges Caching im Web
- Cache Füllung durch Prefetching
- Cache Ersetzung nach verschiedenen Methoden
- Cache Kohärenz mit verschiedenen Methoden

Literatur

- Jia Wang. *A Survey of Web Caching Schemes for the Internet*. ACM Computer Communication Review, 25(9), pp. 36-46, October 1999. http://www.cs.cornell.edu/Info/People/jiawang/web-survey.ps
- Zona Research, Inc. *The Economic Impacts of Unacceptable Web-Site Download Speeds*. April1999 http://www.keynote.com/downloads/whitepapers/economic_impact_of_downloadspeed.pdf
- Brian D. Davison. *A Web Caching Primer*. IEEE Internet Computing, 5(4), pp. 38-45, July/August 2001. http://www.cs.rutgers.edu/~davison/pubs/2001/internetcomputing/pubprimer.ps.gz
- Michael Baentsch, Lothar Baum, Georg Molter, Steffen Rothkugel and Peter Sturm. *Enhancing the Web's Infrastructure: From Caching to Replication*. IEEE Internet Computing, 1(2), pp. 18-27, 1997. http://citeseer.nj.nec.com/baentsch97enhancing.html
- K. Chinen and S. Yamaguchi. *An interactive prefetching proxy server for improvement of WWW latency*. Proceedings of INET'97, June 1997. Siehe http://shika.aist-nara.ac.jp/products/wcol/wcol.html
- R. Fielding, J. Gettys, J. Mogul, H. Frystyk, L. Masinter, P. Leach, T. Berners-Lee. Hypertext Transfer Protocol - HTTP/1.1. RFC 2616. June 1999. http://www.ietf.org/rfc/rfc2616.txt
- I. Cooper, J. Dilley Akamai. Known HTTP Proxy/Caching. RFC 3143. June 2001. http://www.ietf.org/rfc/rfc3143.txt
- Christoph Lindemann, Oliver P. Waldhorst. *Analysis of Web Caching in the Gigabit Research Network G-WiN*. Abschlußbericht zum Projekt Analyse der Wirksamkeit von Web Caching im G-WiN. University of Dortmund. April 2001. http://webdoc.sub.gwdg.de/ebook/ah/dfn/Cache-Analysis.pdf

Zusammenfassung

Zusammenfassung

- Server- und Klientenseitige Verarbeitung
- Caching im Web