Web-basierte Systeme

04: Hypertext Transfer Protocol

Wintersemester 2024

Rüdiger Kapitza

Lehrstuhl für Informatik 4
Systemsoftware

Friedrich-Alexander-Universität
Technische Fakultät

HTTP das Rückgrat des WWW

Vorläufiger Vorlesungsplan

16. Oktober	Einführung und Darstellung von Webseiten
23. Oktober	HTML und CSS
30. Oktober	Hypertext Transfer Protocol
6. November	**Browser Schnittstellen**
13. November	Kommunikationsschnittstellen im Browser
20. November	WebAssembly
27. November	Architektur moderner Browser
4. Dezember	Clientseitige Architekturmuster und serverseitige Implementierung von Web-basierten Systemen
11. Dezember	Vorbereitung Papieranalyse
8. Januar	Papieranalyse
15. Januar	Lastverteilung durch Zwischenspeicher
22. Januar	Web3
29. Januar	Aspekte von Web Sicherheit
5. Februar	Zusammenfassung und Ausblick

Zielsetzung der Lerneinheit

- Verständnis wie mittels HTTP Daten ausgetauscht werden
- Verschlüsselte Übertragung unter Verwendung von HTTPS
- Verbesserungen von HTTP 0.9 bis HTTP/2

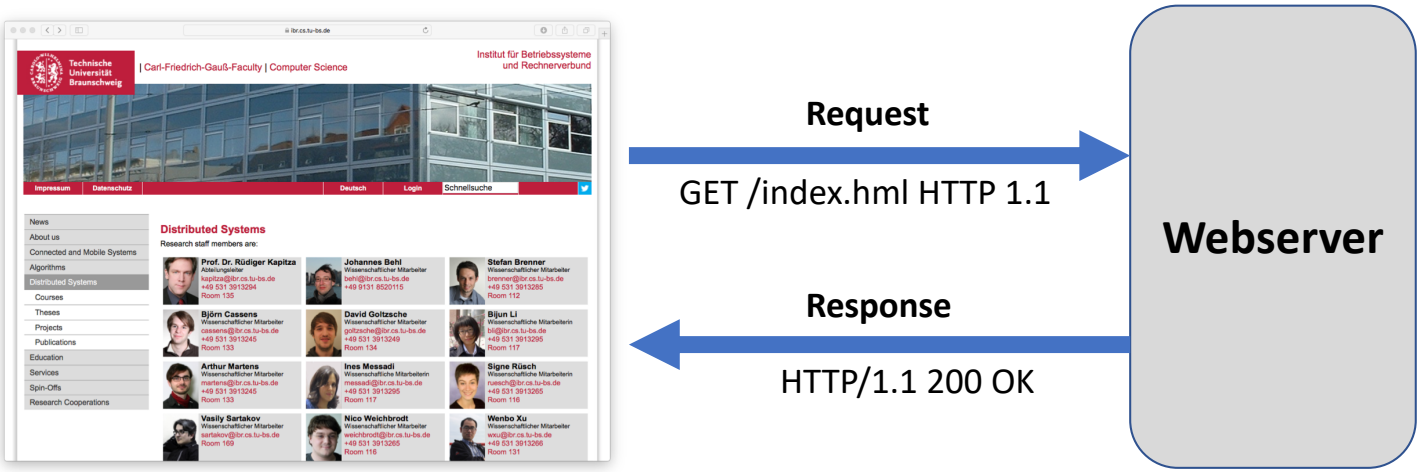

Hypertext Transfer Protocol

Ursprüngliche **Entwicklungsziele von HTTP** (HTTP 0.9)

- Einfache Anfrage/Antwort-basierte Kommunikation
- Eindeutige Identifikation von Ressourcen
  - HTTP-Anfragen beinhaltet einen Uniform Resource Identifier (URI)
- Zustandsloses Protokoll
  - Informationen aus früheren Anforderungen gehen verloren
- Metadaten zur Verhandlung der Übertragung
  - Mittels Header-Informationen und Statuscodes können beliebige Daten übertragen werden

Weiterentwicklung

- Standardisierung erfolgt durch Arbeitsgruppen des W3C und die Internet Engineering Task Force (IETF)
- Meist verbreitete Version ist aktuell HTTP 1.1 - die Neueste: HTTP/3 (RFC 9114, 2022)

Hypertext Transfer Protocol

Hypertext Transfer Protocol (HTTP)

- Ursprüngliche Version 0.9 – bis Juni 2014 Version 1.1
- Textbasiertes Protokoll
  - Einfache Analysierbarkeit (ohne zusätzliche Werkzeuge)

Anfrage-Antwort-Interaktion

- Client sendet Anfragenachricht (`Request`)
- Server sendet Antwortnachricht (`Response`)

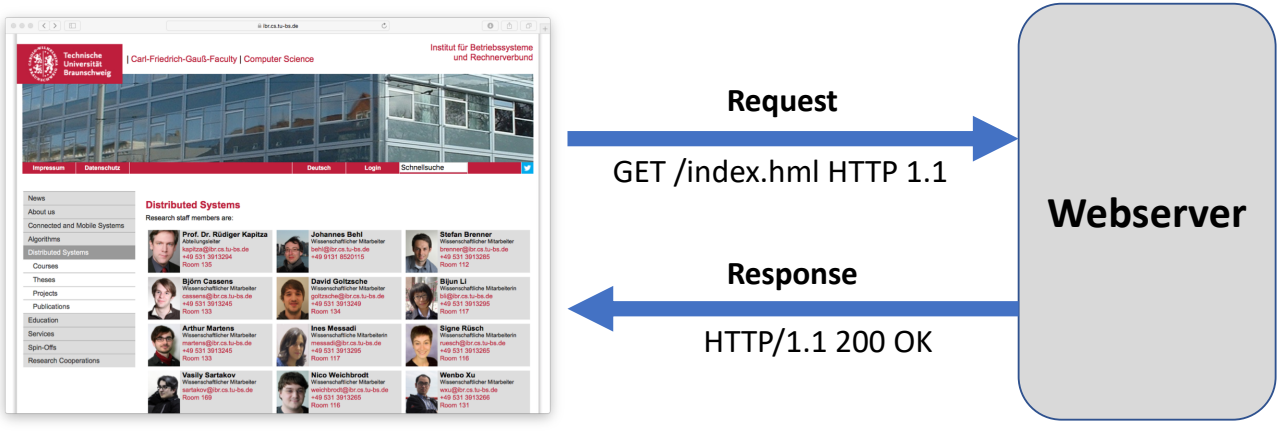

Hypertext Transfer Protocol

Hypertext-Übertragungsprotokoll – technische Einordnung

- HTTP bildet ein Protokoll der Anwendungsschicht
- HTTP benötigt ein zuverlässiges Transportprotokoll
  - D.h. (meist) das Transmission Control Protocol (TCP) (bis HTTP/2)

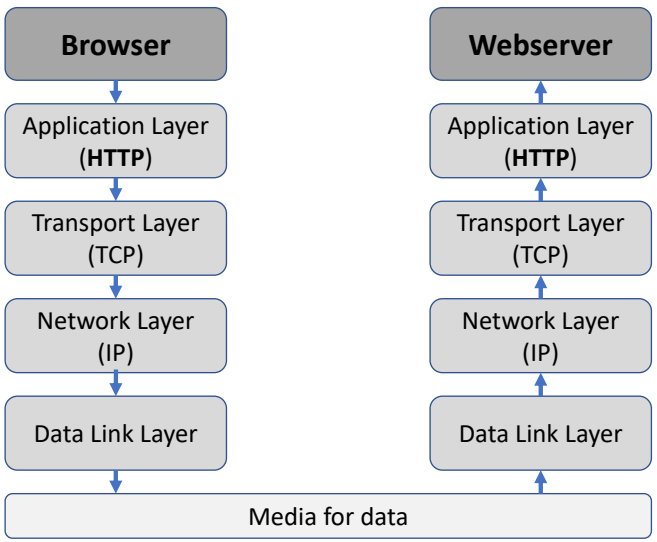

Uniform Resource Identifier

Uniform Resource Identifier (URI)

- eindeutige Referenzierbarkeit von Ressourcen
  - Dokumente, Mailadressen, Mailboxen, Webseiten, …
- einheitliches Schema zur Referenzierung
  - erweiterbares, lesbares und maschinenlesbares Format

Heutige Sichtweise (Contemporary View)

- alles ist eine URI und verschiedene Schemata

Häufige, generische Aufteilung (z.B. bei http: und ftp:)

```
<schema> "://" [ <username> [":" <passwort>] "@" ] <hostname>
               [":" <portnummer>] ["/" <url-pfad>
```

Literatur

- T. Berners-Lee, R. Fielding, L. Masinter: Uniform Resource Identifier (URI): Generic Syntax. IETF, RFC 3986, Jan. 2005.

Nachrichtenaufbau

Anfrage: Request-Methode

- Anfragetyp, Methodenauswahl
  - z.B. `GET /robots.txt HTTP/1.0`
- Request-Header
  - Zusatzinformationen zur Anfrage
  - z.B. `User-Agent: OperMoz` und `Host: www.fau.de`
- Leerzeile
- Optionaler Datenbereich (Body)
  - Inhalt beschrieben durch bestimmten Request-Header (Content-Type)
  - MIME-Type (Multi-Purpose Internet Mail Extension) [Body]

Nachrichtenaufbau

Beispiel für eine GET-Anfrage

```
GET / HTTP/1.1
Host: localhost:6789
Upgrade-Insecure-Requests: 1
Accept: text/html,application/xhtml+xml,application/xml;q=0.9,*/*;q=0.8
User-Agent: Mozilla/5.0 (Macintosh; Intel Mac OS X 10_13_3) AppleWebKit/604.5.6
        (KHTML, like Gecko) Version/11.0.3 Safari/604.5.6
Accept-Language: en-us
Accept-Encoding: gzip, deflate
Connection: keep-alive
```

Methoden

Definierte Methoden

- `GET`: Anfrage nach Daten – identifiziert durch einen URI
  - Daten können vorliegen oder dynamisch erzeugt werden
- `POST`: Schicke Daten
  - Zum Beispiel: Inhalt eines Formulars oder Textfeldes
  - Information wird im Datenbereich der Nachricht abgelegt
  - Ziel der Daten wird durch die URI festgelegt

Typisch für Webserver: `GET` und `POST`

Methoden

Definierte Methoden (Fortsetzung)

- `HEAD`: Hole Response-Header ohne Datenanhang (sonst wie `GET`)
  - Verwendet zu Fehlersuche und Validitätsprüfung von URIs
- `PUT`: Speichere Daten
  - Erzeugt eine Ressource, wenn sie noch nicht vorhanden ist
- `DELETE`: Löscht durch URI referenzierte Ressource
- `OPTIONS`: Hole Serverinformationen
  - z.B. ob PUT für eine Datei unterstützt wird

Nachrichtenaufbau – Antwort

Antwort: HTTP-Response

- Status der Antwort
  - z.B. `HTTP/1.0 200 OK`
- Response-Header
  - Zusatzinformationen zur Antwort
  - z.B. `Server: apache/2.0`
- Leerzeile
- optionaler Datenbereich (Body)

Daten

- Beliebig (orientiert an MIME-Types)
  - z.B. `Content Type: text/html`
- Mehrere Einzelteile durch Multipart-Typen
  - z.B. `multipart/mixed`

Nachrichtenaufbau

Beispiel für eine HTTP Antwort (gekürzt!):

```
HTTP/1.1 200 OK
Date: Mon, 09 Apr 2018 07:51:40 GMT
Server: Apache/2.4.18 (Ubuntu)
Strict-Transport-Security: max-age=31536000; includeSubDomains
Public-Key-Pins: pin-sha256="SdNy5BOgYHobIdEHk3CdsPUwgIiiMctIM5eVeDPN4qg="; ...
X-Frame-Options: SAMEORIGIN
X-Xss-Protection: 1; mode=block
X-Content-Type-Options: nosniff
Last-Modified: Wed, 22 Jun 2016 11:46:03 GMT
ETag: "1d6-535dc7b6b7f7e"
Accept-Ranges: bytes
Content-Length: 470
Vary: Accept-Encoding
Content-Type: text/plain

User-agent: *
Disallow: /projects/tclouds/download
Disallow: /projects/caprice
Disallow: /login
...
```

- Erzeugt via: `curl –verbose https://www.ibr.cs.tu-bs.de/robots.txt`

Nachrichtenaufbau – Antwort

HTTP Statuscodes

- **1xx** – Informational responses
  - `102 Processing` – Verhindert ein Timeout auf Browserseite
- **2xx** – Success
  - `200 OK`
- **3xx** – Redirection – „Location“-Header-Feld sagt, wo die Daten zu finden sind
  - `301 Moved Permanently`
- **4xx** – Client errors
  - `400 Bad Request` – Anfrage-Nachricht war fehlerhaft aufgebaut
- **5xx** – Server errors
  - `500 Internal Server Error` – „Sammel-Statuscode“ für unerwartete Serverfehler.
  - `501 Not Implemented`

Abbildung von HTTP-Anfragen auf TCP/IP

In den Anfangstagen des WWW (HTTP 0.9-1.0):

- Eine **TCP/IP-Verbindung pro Anfrage/Antwort-Paar**
- Server sind völlig zustandslos

- Wiederkehrende Etablierung von neuen Verbindungen ist aufwendig
  - TCP Drei-Wege-Handschlag und *slow-start*
  - Bereitstellung von Systemressourcen

Literatur

- Hypertext Transfer Protocol – HTTP/1.0. IETF, RFC 1945, May 1996.

Aufbau aktueller Webseiten

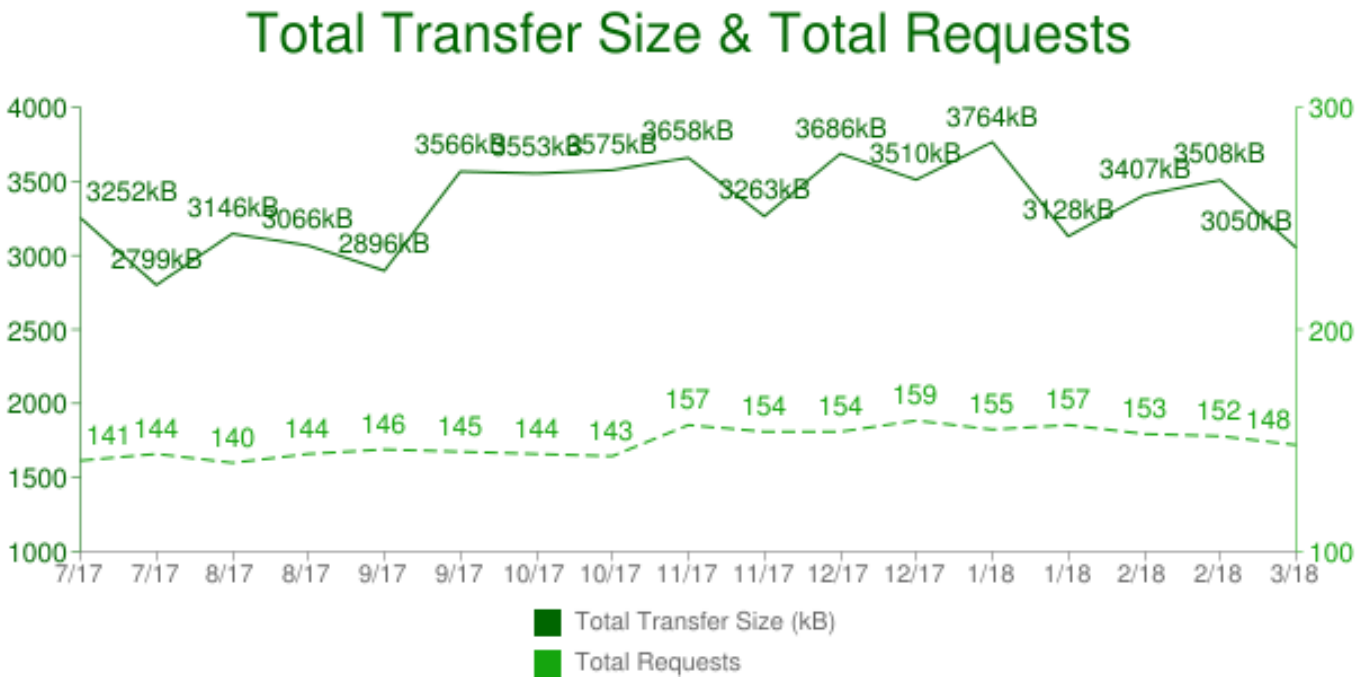

- Top 1000 Websites zwischen 1. Juli 2017 – 1. März 2018 (`http://httparchive.org/`)

$\Rightarrow$ Heutige Webseiten setzen sich aus vielen Teilen zusammen!

Abbildung von HTTP auf TCP/IP

Verbesserungen durch HTTP 1.0 und 1.1

- Wiederverwendung der Verbindung
  - Mehrere Anfragen über die gleiche Verbindung
  - Standard für HTTP 1.1 und konfigurierbar für HTTP 1.0 (`Connection: Keep-Alive`)
- Zusätzlich ist *Pipelining* möglich (HTTP 1.1)
  - Mehrere Anfragen hintereinander (über eine Verbindung)
  - Antworten kommen in gleicher Reihenfolge später
- **Problem:** Head-of-Line Blocking
  - Wenn eine Anfrage ins Stocken gerät, werden alle folgenden gebremst!
  - Oft mehrere parallel TCP-Verbindungen (bspw. 2-8)
    - Hier gibt es aber auch Beschränkungen durch den Server

Literatur

- Hypertext Transfer Protocol – HTTP/1.1. IETF RFC 2616, June 1999.

HTTP Secure

Sicherheitsmängel von HTTP

- **Privatheit** – Informationsaustausch erfolgt im Klartext
- **Integrität** – ausgetauschte Information kann manipuliert werden
- **Authentifizierung** – Zugangsdaten werden ungeschützt übertragen

HTTP Secure (HTTPS) als Lösung

- HTTPS realisiert HTTP unter Verwendung der Secure Socket Layer (SSL)
- Nachrichten werden vor Austausch verschlüsselt und am Zielort entschlüsselt

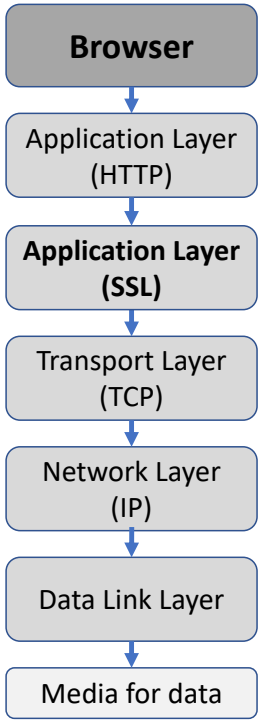

HTTP Secure

Technische Einbindung

- Eigener Standardport: **443** im Gegensatz zu Port **80**
- URIs beginnen mit `https`
- Der Secure Socket Layer wird genutzt um Verschlüsselungsverfahren und Schlüssel auszuhandeln

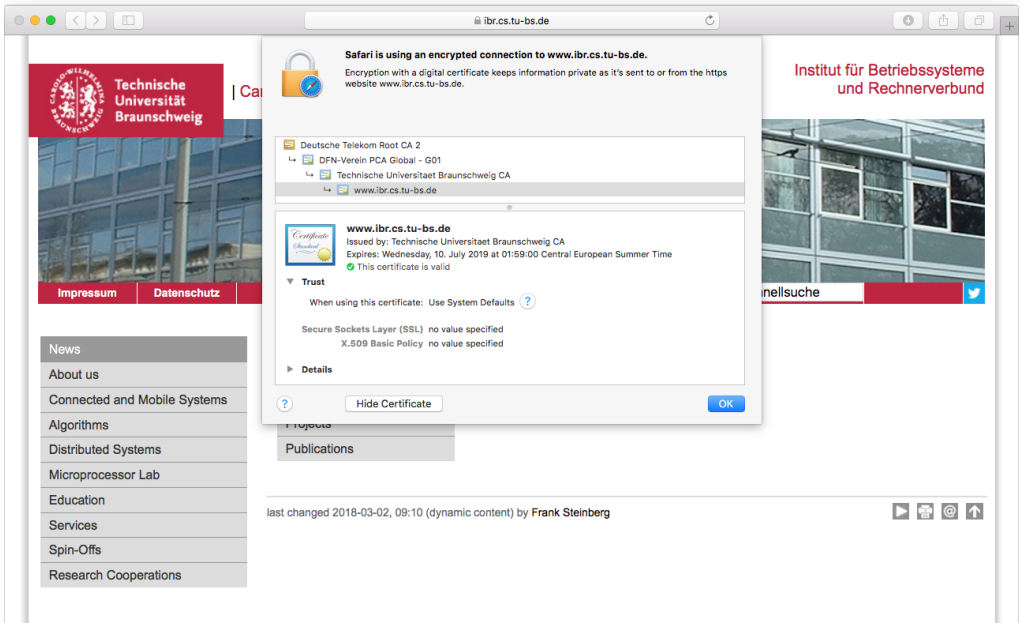

HTTP Secure

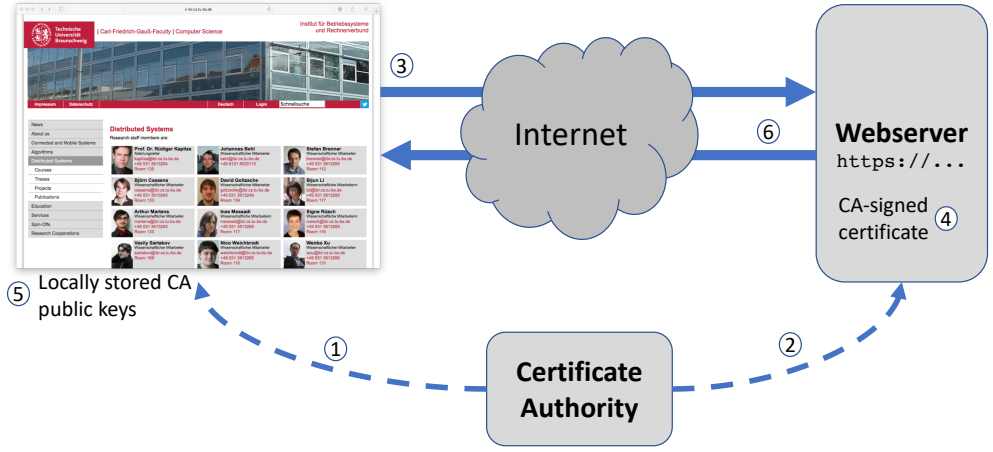

1. Aktuelle Browser werden mit verschiedenen Root-Zertifikaten ausgeliefert. Diese enthalten den öffentlichen Schlüssel der jeweiligen Zertifizierungsstelle.
2. `https` setzt voraus, dass ein von einer Zertifizierungsstelle signiertes Zertifikat vorliegt.
3. Beim Verbindungsaufbau zum Webserver werden die unterstützten Verschlüsselungsverfahren mitgeteilt.

HTTP Secure

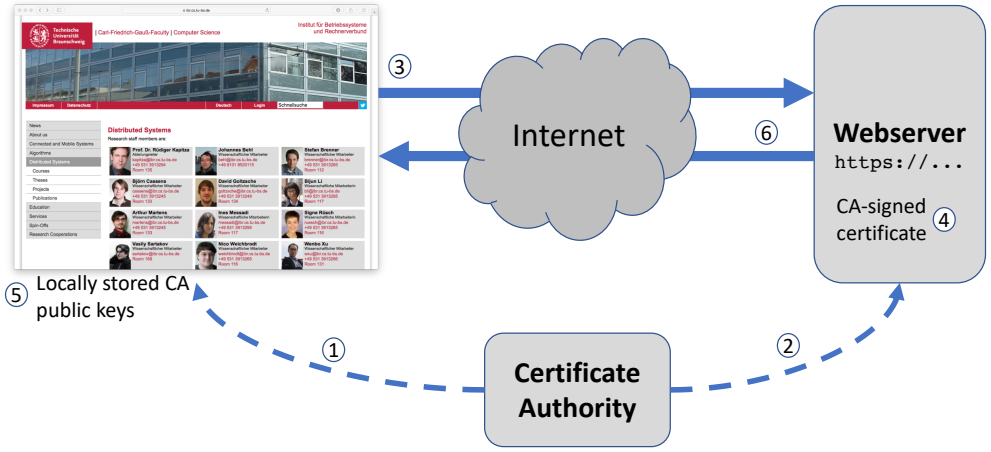

4. Als Antwort auf die Verbindungsanforderung wird das von der Zertifizierungsstelle signierte Zertifikat übertragen.
5. Es wird geprüft, ob das Zertifikat korrekt signiert ist und der Verbindungsaufbau abgeschlossen
6. Bei erfolgreichem Verbindungsaufbau kann nun der Datenaustausch erfolgen

HTTP Secure - Verbindungsaufbau

- Browser initiiert sichere Verbindung

  `https://www.ibr.cs.tu-bs.de`
- Bei Aufbau erfolgt ein SSL-Handschlag
- Als Ergebnis werden Verfahren und weitere Parameter etabliert
- (Sehr vereinfachte Darstellung!)

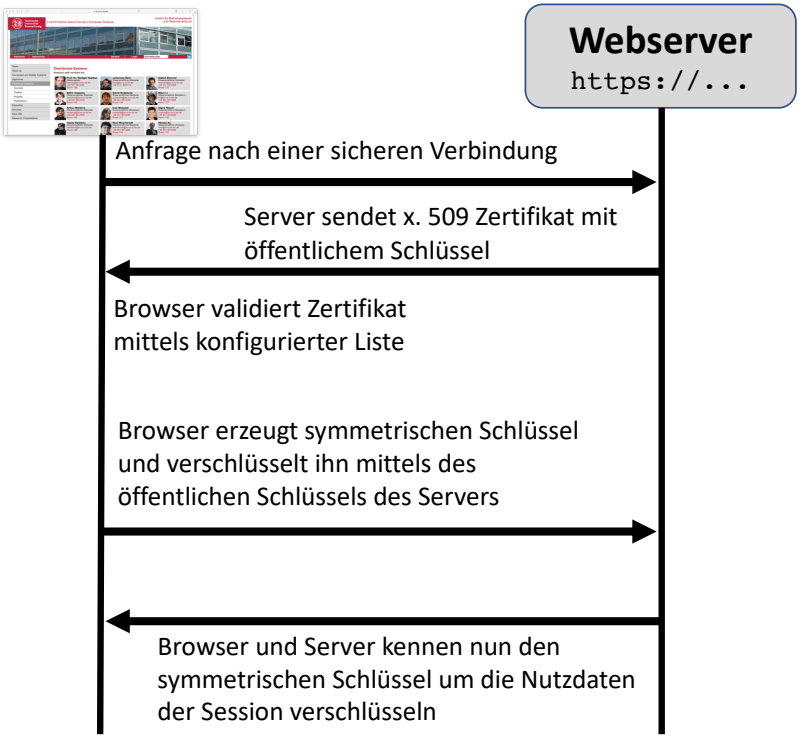

HTTP/2

Zielsetzung: Adressierung der Probleme von HTTP 1.0 und 1.1

- Reduktion der Empfindlichkeit gegenüber variablen RTTs
- Adressierung der Head-of-line Blocking Problematik
- Vermeiden von parallelen TCP-Verbindungen
- ...dennoch soll die Semantik von HTTP 1.1 erhalten bleiben!
  - Anwendungen müssen nicht umgeschrieben werden

Entstehungsgeschichte

- Entwicklung von HTTP/2 begann 2009 mit SPDY bei Google
  - Zielsetzung: **Halbierung** der Ladezeit für typische Webseiten!
- Seit 2012 unterstützen durch Chrome, Firefox und Opera
- Als Konsequenz leitet die IETF HTTP Working Group einen Standardisierungsprozess ein
- Mai 2015 wurden der RFC 7540 (HTTP/2) und der RFC 7541 (HPACK) veröffentlicht

HTTP/2 kompakter Überblick

- **Eine TCP Verbindung** für die gesamte Kommunikation mit einem Webserver
- Anfrage $\rightarrow$ Stream
  - Multiplexen von Streams
  - Streams haben Prioritäten
- Binary-framing Schicht
  - Priorisierung
  - Flusskontrolle
  - Server push
    - Seit 2022 nicht mehr von Chrome unterstützt
- Header Kompression (HPACK)

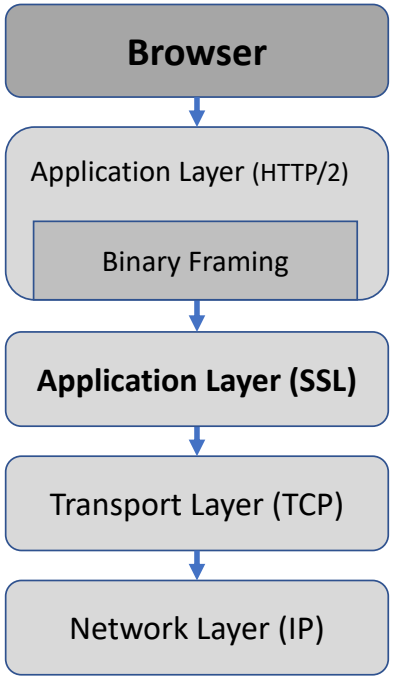

HTTP/2 Binary Framing Layer

- Redefiniert wie HTTP Nachrichten ausgetauscht werden
- Layer ist für Anwendungs- und Socket-Schicht **transparent**
- Browser und HTTP-Server müssen angepasst werden
- HTTP Nachrichten werden in kleinere binärkodierte Nachrichten unterteilt
- Direkte Lesbarkeit geht verloren
  - Werkzeuge zur Protokollanalyse werden benötigt

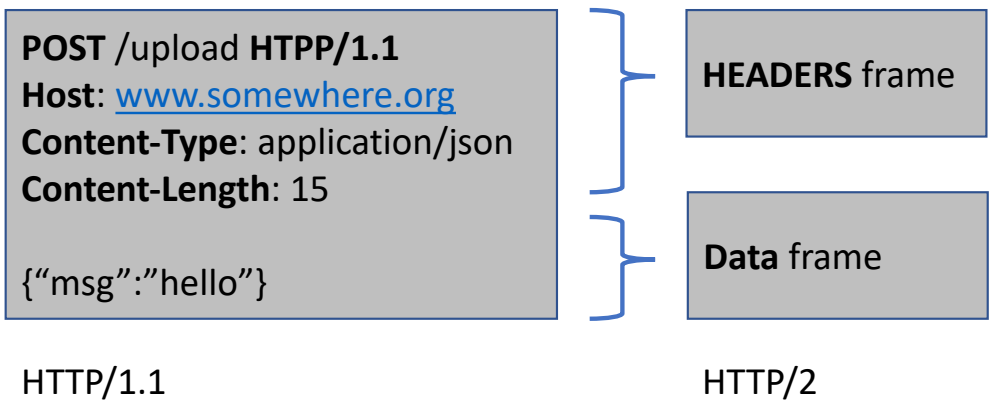

Logischer Aufbau einer HTTP/2 Verbindung

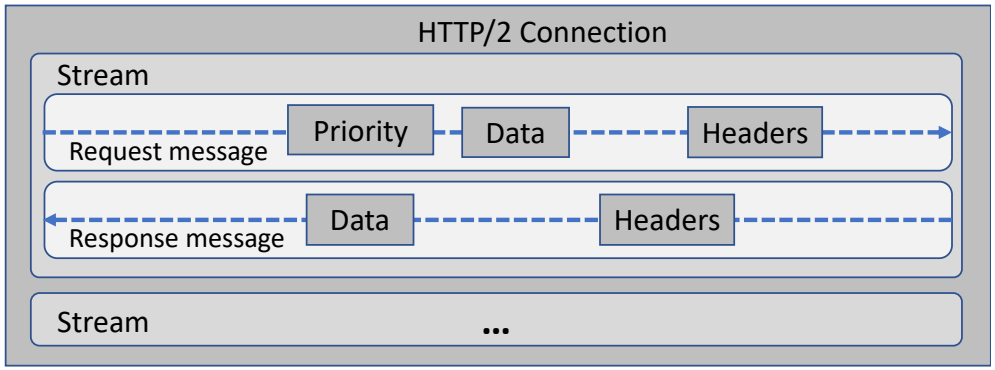

Struktur einer HTTP/2 Verbindung

- Ein **Stream** bildet eine bidirektionale Verbindung über die Nachrichten (Messages) ausgetauscht werden
- **Message** eine Sequenz von Frames die zusammen eine (HTTP)-Anfrage- oder Antwortnachricht bilden
- **Frame** kleinste logische Einheit zur Datenübertragung
  - Jeder Frame hat einen Protokollkopf, der mindestens eine Zuordnung zu einem Stream enthält.

HTTP/2 Multiplexing

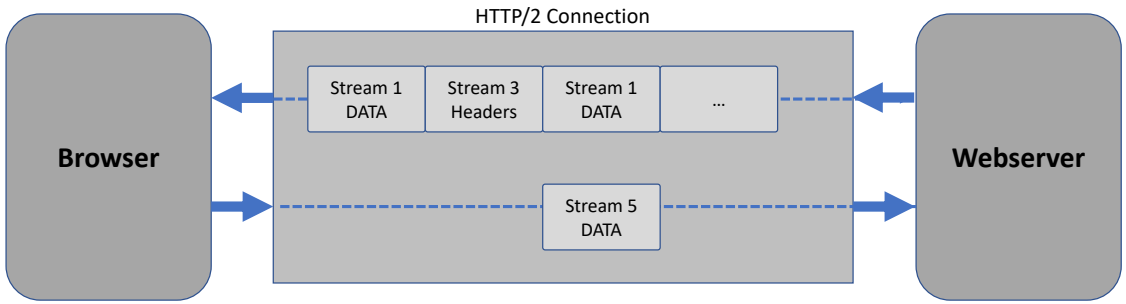

- HTTP/2 ermöglicht es über eine Verbindung
  - mehrere Anfragen und Antworten parallel zu vermitteln
  - nur eine einzige TCP Verbindung zu nutzen
  - und macht bisherige HTTP/1.x Optimierung obsolet
    - z.B. *image sprites*

Priorisierung bei HTTP/2

- Zielsetzung ist es die übertragenen Daten so zu organisieren, dass sich eine Webseite möglichst schnell aufbaut
- Durch Priorisierung kann der Browser dem Webserver mitteilen, welche Inhalte wann benötigt werden.
- Entsprechende Hinweise können sich dynamisch ändern:
  - Z.B. wird das HTML einer Webseite primär benötigt, danach CCS und im folgenden Grafiken
  - Bei Grafiken kann dies z.B. davon abhängen, ob der Benutzer die Maus auf die für die Grafik vorgesehene Stelle bewegt.
- Webserver müssen diesen Hinweisen *nicht* folgen
  - Sind hoch priorisierte Daten aktuell nicht verfügbar – können andere Daten versendet werden

Priorisierung: Technische Umsetzung

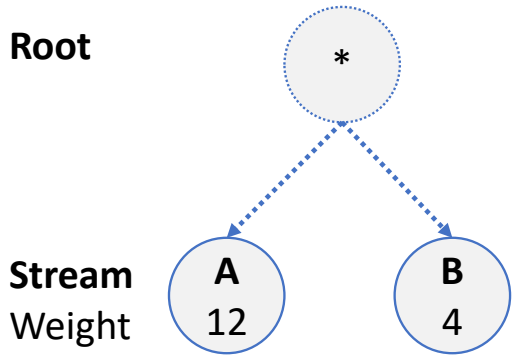

Technische Umsetzung

- Jeder Stream erhält ein Gewicht zwischen 1 und 256
  - Je höher das Gewicht, desto mehr Ressourcen werden angefordert
- Jeder Stream kann eine Abhängigkeit angeben
  - Abhängigkeiten haben Vorrang!
- Wird keine Abhängigkeit angegeben, so ist implizit eine Abhängigkeit zur Wurzel der Webseite gegeben

Priorisierung: Technische Umsetzung

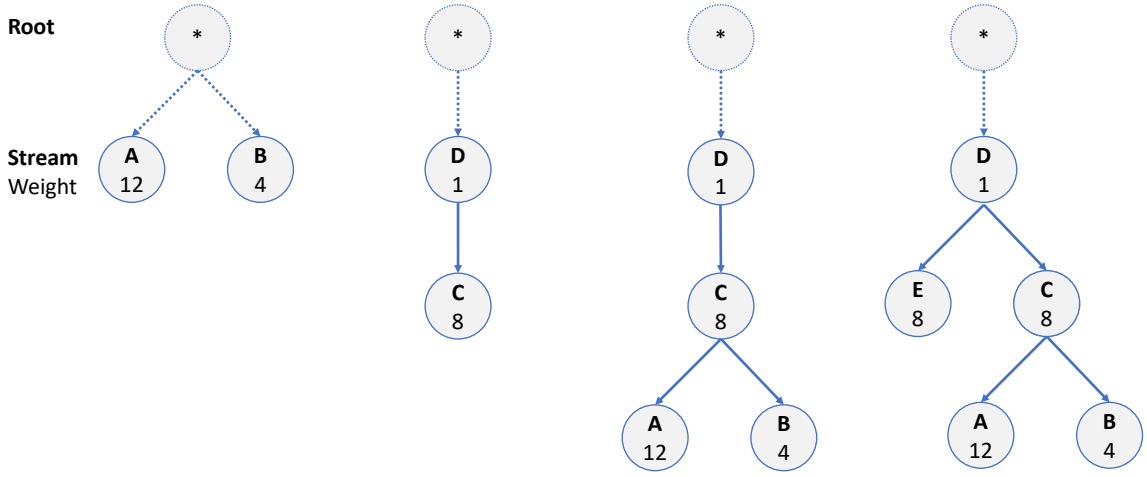

Technische Umsetzung (Fortsetzung)

- Basierend auf der Gewichtung und den Abhängigkeiten entstehen Anforderungsbäume
  1. A und B teilen sich die Ressourcen 3/4 zu 1/4
     - Gewichte dieser Ebene durch das entsprechende Gewicht des Knotens
  2. Erst erhält D alle Ressourcen, dann C

HTTP/2 Flusskontrolle

Wozu wird FlussKontrolle bei HTTP/2 benötigt?

- Beispiel: Browser hat ein Video mit hoher Bandbreite angefordert – der Benutzer pausiert aber den Mediastream
- Beispiel: Proxy Server hat mehr Systemressourcen als der Endbenutzer und will deshalb den Transfer zwischen sich und dem Webserver beschränken
- Greift hier nicht schon TCP?
  - $\Rightarrow$ Nein, tut es nicht, da TCP nur die gesamte Verbindung regelt, nicht aber die einzelnen Datenströme

HTTP/2 Flusskontrolle

Technische Umsetzung

- Jeder Empfänger kann pro Stream und Verbindung eine Fenstergröße festlegen
- Die Fenstergröße wird durch einen Empfänger beim Verbindung- und Streamaufbau vermittelt (SETTINGS Frame)
- Durch die Vermittlung von DATA Frames wird das Übertragungsfenster reduziert und durch WINDOW_UPDATE Frames wieder vergrößert
- Standardfenstergröße ist 65535 Bytes, wann genau das Übertragungsfenster verändert wird ist Aufgabe der Implementierung und nicht festgelegt.

HTTP/2 Server Push

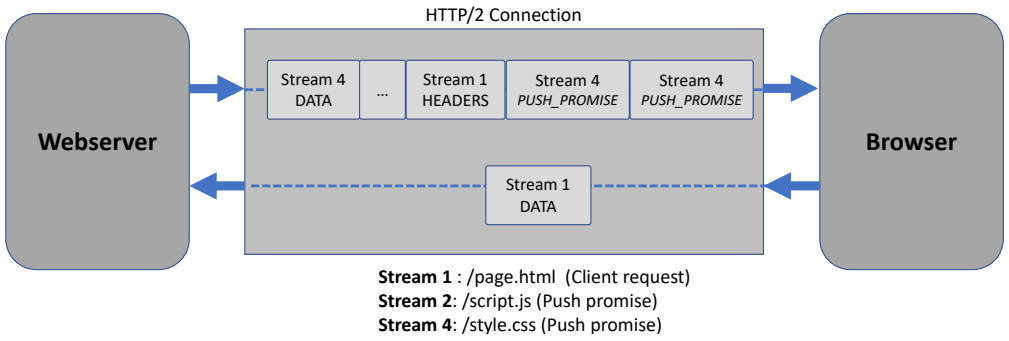

Server Push

- Server kann auf eine Anfrage mehrere Antworten schicken
- Annahme: Informationen werde ohnehin benötigt!
  - Beispiel: Seite referenziert eine CSS und ein JavaScript Datei
- Zielsetzung ist es Informationen verfügbar zu machen, bevor sie im Browser benötigt werden
  - In Bezug auf HTTP/1.x macht dies *Inlining* obsolet!
  - Vorzüge gegenüber Inlining – Daten können wie normale Ressourcen behandelt werden

HTTP/2 Server Push

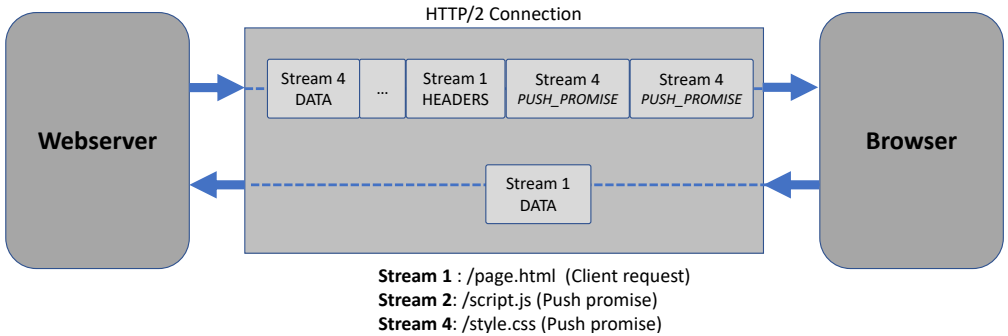

Technische Umsetzung

- Proaktiv bereitgestellte Ressourcen via PUSH_PROMISE Frames
- Browseranfragen und PUSH_PROMISE Frames dürfen sich nicht überholen!
  - Lsg.: PUSH_PROMISE Frames und dann die Antwort versenden
- Browser kann PUSH_PROMISE Frames ablehnen (RST_STREAM) falls Daten schon lokal vorhanden
- Browser behält Kontrolle über die Nutzung
  - Bspw. kann er über SETTINGS Frame dies unterbinden

Wandel der Zeit: Removing HTTP/2 Server Push from Chrome

- `https://developer.chrome.com/blog/removing-push/`

HTTP/2 Header Komprimierung

- Header-Daten werden bei HTTP/1.x immer als Text gesendet und können zwischen 500-800 Byte groß sein, oft aber auch größer

$\Rightarrow$ Speziell bei kleineren Ressourcen ist der Overhead für Metadaten recht hoch!

- HTTP/2 reduziert dies durch zwei Maßnahmen:
  1. Einzelne Felder eines Headers werden Huffman enkodiert
  2. Es wird ein gemeinsamer Kontext aufgebaut, in dem bereits gesendete Inhalte nur noch über einen Index übertragen werden.

HTTP/2 Header Komprimierung

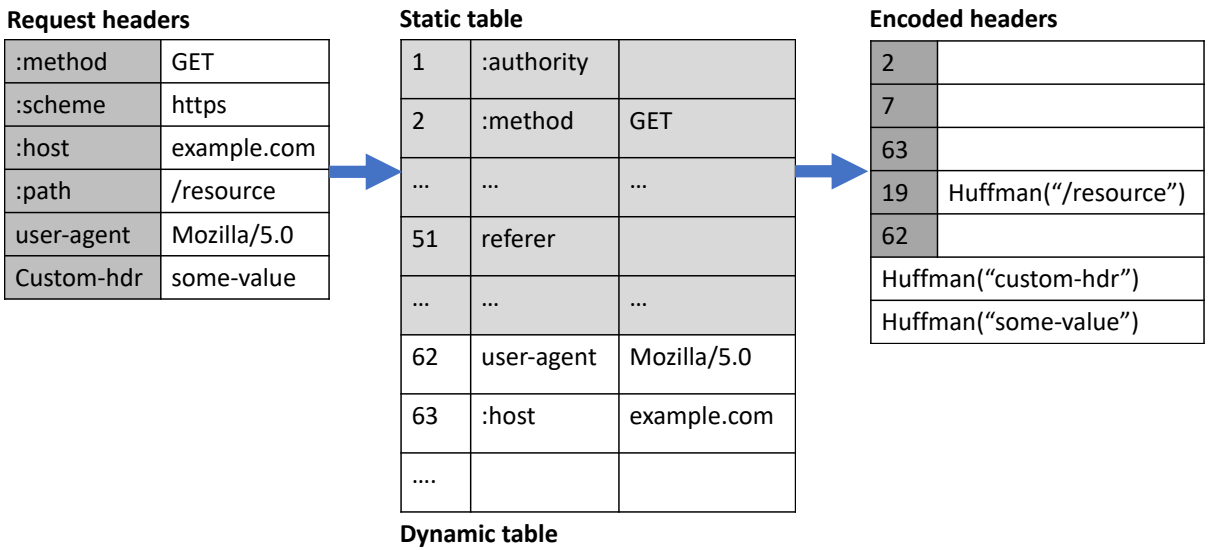

- Einführung einer statischen und einer dynamischen Tabelle
  - Die statische Tabelle wird in der Spezifikation definiert und enthält allgemeine Header-Felder
  - Die dynamische Tabelle wird pro Verbindung etabliert

Aufbau einer HTTP/2 Verbindung

- Die Transition zu HTTP/2 ist ein langlaufender Prozess
- Aktuell unterstützen alle etablierten Browser HTTP/2, aber nicht alle Webserver
- Es bestehen 3 Wege um eine HTTP/2 Verbindung zu etablieren:
  1. Aufbau zusammen mit TLS-Verbindung über ALPN (Standard)
  2. Upgrade einer normalen Verbindung (via HTTP upgrade)
  3. Pro-aktiver Aufbau einer HTTP/2 auf Grund von Vorwissen (z.B. DSN-Eintrag)
- Aktuelle Verfügbarkeit laut w3techs.com für die 10 Million beliebtesten Webseiten: 50,8%

Zusammenfassung

- Verständnis wie mittels HTTP Daten austauschen werden
- Verschlüsselte Übertragung unter Verwendung von HTTPS
- Verbesserungen von HTTP 0.9 bis HTTP/2
  - HTTP/2 eröffnet viele neue Möglichkeiten und macht eine Reihe von Workarounds obsolet
- HTTP/3 als nächster Schritt
  - Verwendung von QUIC welches UDP nutzt, zur Verbesserung der Widerstandsfähigkeit bei Paketverlusten

Referenzen

- High Performance Browser Networking `https://hpbn.co`