Warstwa aplikacji

część 1: HTTP

Sieci komputerowe

Wykład 8

Marcin Bieńkowski

Trochę statystyk: całkowity ruch (2022)

CATEGORY TRAFFIC SHARE

TOTAL TRAFFIC

	Category	Total Volume
1	Video	53.72%
2	Social	12.69%
3	Web	9.86%
4	Gaming	5.67%
5	Messaging	5.35%
6	Marketplace	4.54%
7	File Sharing	3.74%
8	Cloud	2.73%
9	VPN	1.39%
10	Audio	0.31%

Obrazek ze raportu https://www.sandvine.com/phenomena

Trochę statystyk: aplikacje (2022)

GLOBAL APP TRAFFIC SHARE

DOWNSTREAM TRAFFIC ⬇

	Category	Total Volume
1	YouTube	16.37%
2	Netflix	10.61%
3	Facebook	7.67%
4	Facebook video	4.83%
5	TikTok	4.48%
6	HTTP Media Stream	4.07%
7	Generic QUIC	4.03%
8	HTTP	2.63%
9	Playstation Download	2.27%
10	iTunes Store	2.12%

GLOBAL APP TRAFFIC SHARE

UPSTREAM TRAFFIC ⬆

	Category	Total Volume
1	BitTorrent	9.70%
2	HTTP	9.05%
3	Google	8.02%
4	Facebook	5.77%
5	Wordpress	5.01%
6	YouTube	4.45%
7	iCloud	4.09%
8	Generic QUIC	3.70%
9	Netflix	3.00%
10	Facebook Messenger	2.37%

Obrazek ze raportu https://www.sandvine.com/phenomena

Trochę statystyk: aplikacje (2022)

GLOBAL APP TRAFFIC SHARE

DOWNSTREAM TRAFFIC ⬇

	Category	Total Volume
1	YouTube	16.37%
2	Netflix	10.61%
3	Facebook	7.67%
4	Facebook video	4.83%
5	TikTok	4.48%
6	HTTP Media Stream	4.07%
7	Generic QUIC	4.03%
8	HTTP	2.63%
9	Playstation Download	2.27%
10	iTunes Store	2.12%

HTTP

GLOBAL APP TRAFFIC SHARE

UPSTREAM TRAFFIC ⬆

	Category	Total Volume
1	BitTorrent	9.70%
2	HTTP	9.05%
3	Google	8.02%
4	Facebook	5.77%
5	Wordpress	5.01%
6	YouTube	4.45%
7	iCloud	4.09%
8	Generic QUIC	3.70%
9	Netflix	3.00%
10	Facebook Messenger	2.37%

Obrazek ze raportu https://www.sandvine.com/phenomena

HTTP (Hypertext Transfer Protocol)

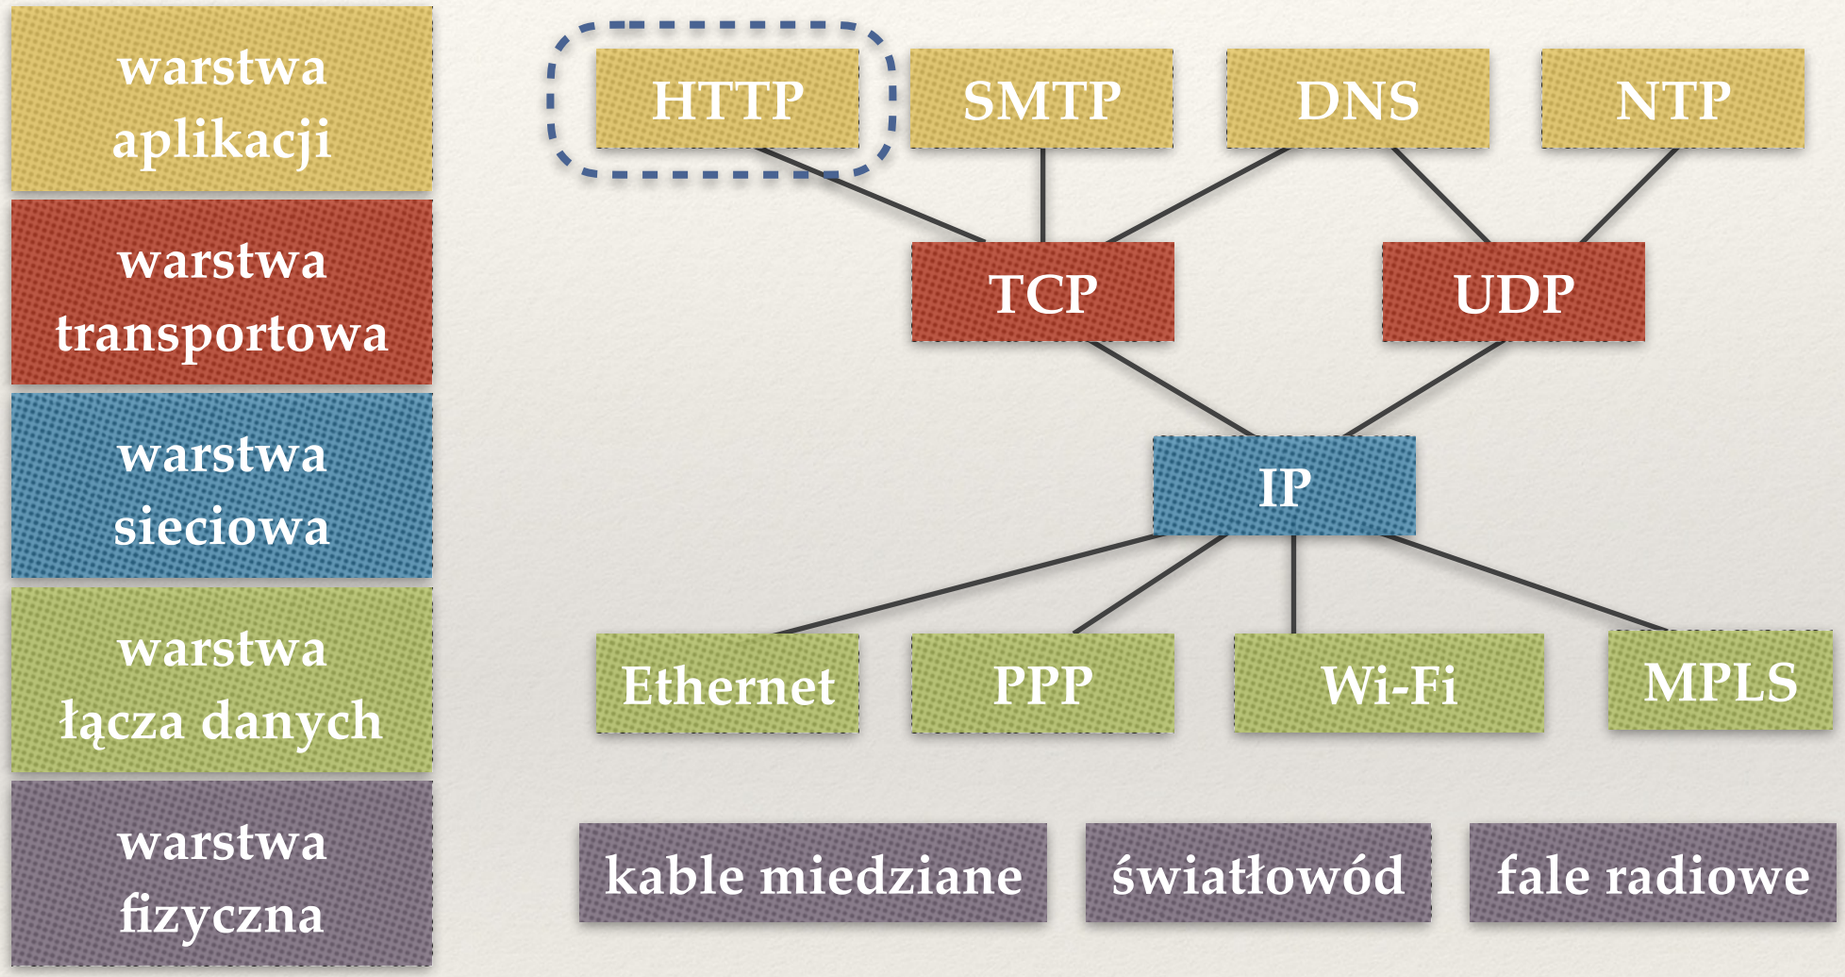

HTTP/1.1

HTTP

- Zaprojektowany do przesyłania hipertekstu (tekst z odnośnikami).
- Obecnie: również do przesyłania przesyłania olbrzymich danych, streamingu video (Youtube, Netflix), …
- Korzysta z protokołu TCP, portu 80 (szyfrowana wersja: port 443).

URL (Uniform Resource Locator)

Identyfikuje dany zasób.

- Składa się z 2 części rozdzielonych dwukropkiem:
  - schemat: (`http`, `https`, `ftp`, `mailto`, ...)
  - część zależna od rodzaju zasobu.

- Przykłady:
  - `http://www.ii.uni.wroc.pl/index.html`
  - `https://pl.wikipedia.org/wiki/URL`
  - `mailto:jan.kowalski@serwer.com`

URL dla schematu http lub https

- Po dwukropku:
  - `//`
  - nazwa serwera WWW
  - opcjonalnie `:port`
  - `/`
  - identyfikator zasobu wewnątrz serwera:
    - niekoniecznie ścieżka do pliku,
    - `/` w identyfikatorze wskazuje na hierarchię.

- Przykład: `https://en.wikipedia.org:443/wiki/HTTP/3`.

Pobieranie strony WWW krok po kroku (1)

- Przeglądarka WWW dostaje URL.
- URL jest rozbijany na części.
- Nawiązuje połączenie TCP z portem 80 serwera WWW.
- Wysyła żądanie HTTP:

```
GET /wiki/HTTP/3 HTTP/1.1
Host: en.wikipedia.org
Accept: text/html;q=0.9,application/xml;q=0.8
Accept-Language: en-US,en;q=0.8,pl;q=0.6,de;q=0.4
User-Agent: Mozilla/5.0 … Chrome/49.0.2623.112
Referer: https://www.google.com/
```

Pobieranie strony WWW krok po kroku (2)

- Serwer analizuje żądanie, pobiera z dysku odpowiedni plik.
- Serwer sprawdza typ MIME (*Multipurpose Internet Mail Extensions*) pliku (heurystyki na podstawie tego jak plik wygląda, rozszerzenia itp.). Przykłady:
  - `text/plain`
  - `text/html`
  - `image/jpeg`
  - `video/mpeg`
  - `application/msword` — dokument `.doc(x)`
  - `application/pdf` — dokument PDF
  - `application/octet-stream` — ciag bajtów bez interpretacji

Pobieranie strony WWW krok po kroku (3)

- Serwer wysyła odpowiedź:

```
HTTP/1.1 200 OK
Server: Apache/2.4.38 … OpenSSL/0.9.8k
Last-Modified: Wed, 29 Apr 2020 21:58:30 GMT
Content-Length: 5387
Content-Type: text/html
```

typ MIME wysyłanego pliku

```
PLIK (w tym przypadku dokument HMTL)
```

- Serwer zamyka połączenie TCP (lub czeka na następne polecenie).
- Przeglądarka wykonuje akcję w zależności od typu MIME (wyświetla, używa wtyczki, używa zewnętrznej aplikacji, …).

Typy odpowiedzi HTTP

- `1xx`: informacyjne.
- `2xx`: sukces (`200` = OK).
- `3xx`: przekierowania do strony *X* (po otrzymaniu przeglądarka wykona zapytanie HTTP o stronę *X*).
- `4xx`: błąd po stronie klienta (błędne żądanie, brak autoryzacji, zabroniony dostęp, `404` = Not Found).
- `5xx`: błąd po stronie serwera (`500` = Internal Server Error).

Hipertekst

- Wiele standardów: HTML, XHTML, XML, …
- Dokument zawiera:
  - odnośniki do innych dokumentów
  - oraz odnośniki do elementów osadzonych w dokumencie, m.in.:
    - obrazki i filmy,
    - skrypty w javascript,
    - arkusze stylów CSS (definiują wygląd, HTML określa tylko strukturę),
    - czcionki.
- Elementy osadzone są pobierane przez kolejne żądania HTTP i wyświetlane przez przeglądarkę.

Bezstanowość

- **Protokół HTTP jest bezstanowy**
  - Serwer nie pamięta poprzednich żądań klienta.
  - Zapytanie klienta musi zawierać wszystkie informacje potrzebne serwerowi.

Bezstanowość

- **Protokół HTTP jest bezstanowy**
  - Serwer nie pamięta poprzednich żądań klienta.
  - Zapytanie klienta musi zawierać wszystkie informacje potrzebne serwerowi.

- **To jak działają:**
  - koszyk w sklepie internetowym?
  - ustawienie języka czy innych preferencji?

Aplikacje po stronie serwera HTTP

Takie zapytanie można zrobić np. formularzem w którym użytkownik wpisze „3”.

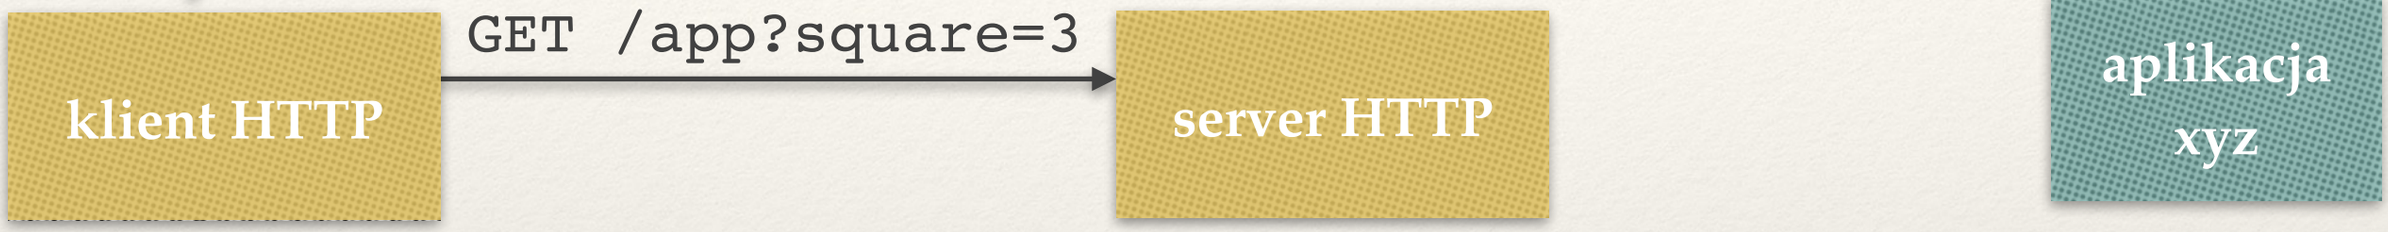

Aplikacje po stronie serwera HTTP

Takie zapytanie można zrobić np. formularzem w którym użytkownik wpisze „3”.

Skonfigurowany, żeby rzeczy zaczynające się od `/app` przekazywać do aplikacji xyz.

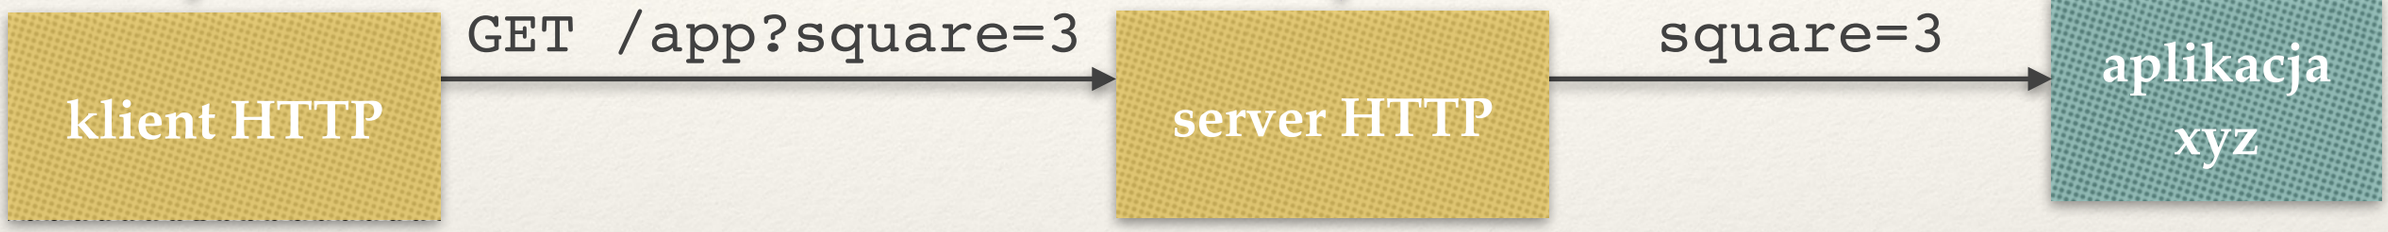

Aplikacje po stronie serwera HTTP

Takie zapytanie można zrobić np. formularzem w którym użytkownik wpisze „3”.

Skonfigurowany, żeby rzeczy zaczynające się od `/app` przekazywać do aplikacji xyz.

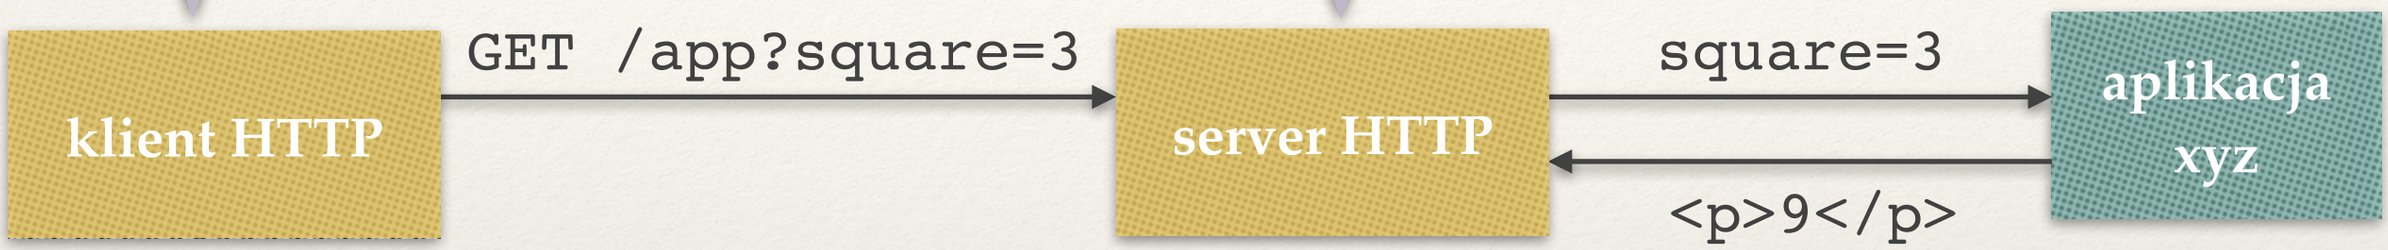

Aplikacje po stronie serwera HTTP

Takie zapytanie można zrobić np. formularzem w którym użytkownik wpisze „3”.

Skonfigurowany, żeby rzeczy zaczynające się od `/app` przekazywać do aplikacji xyz.

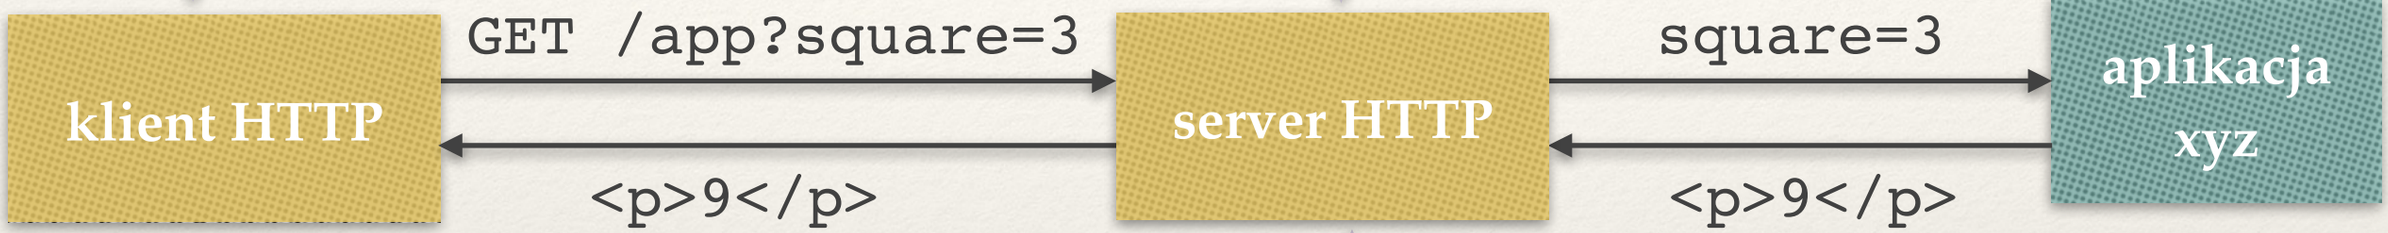

Serwer zazwyczaj nie modyfikuje odpowiedzi aplikacji.

Aplikacje po stronie serwera HTTP

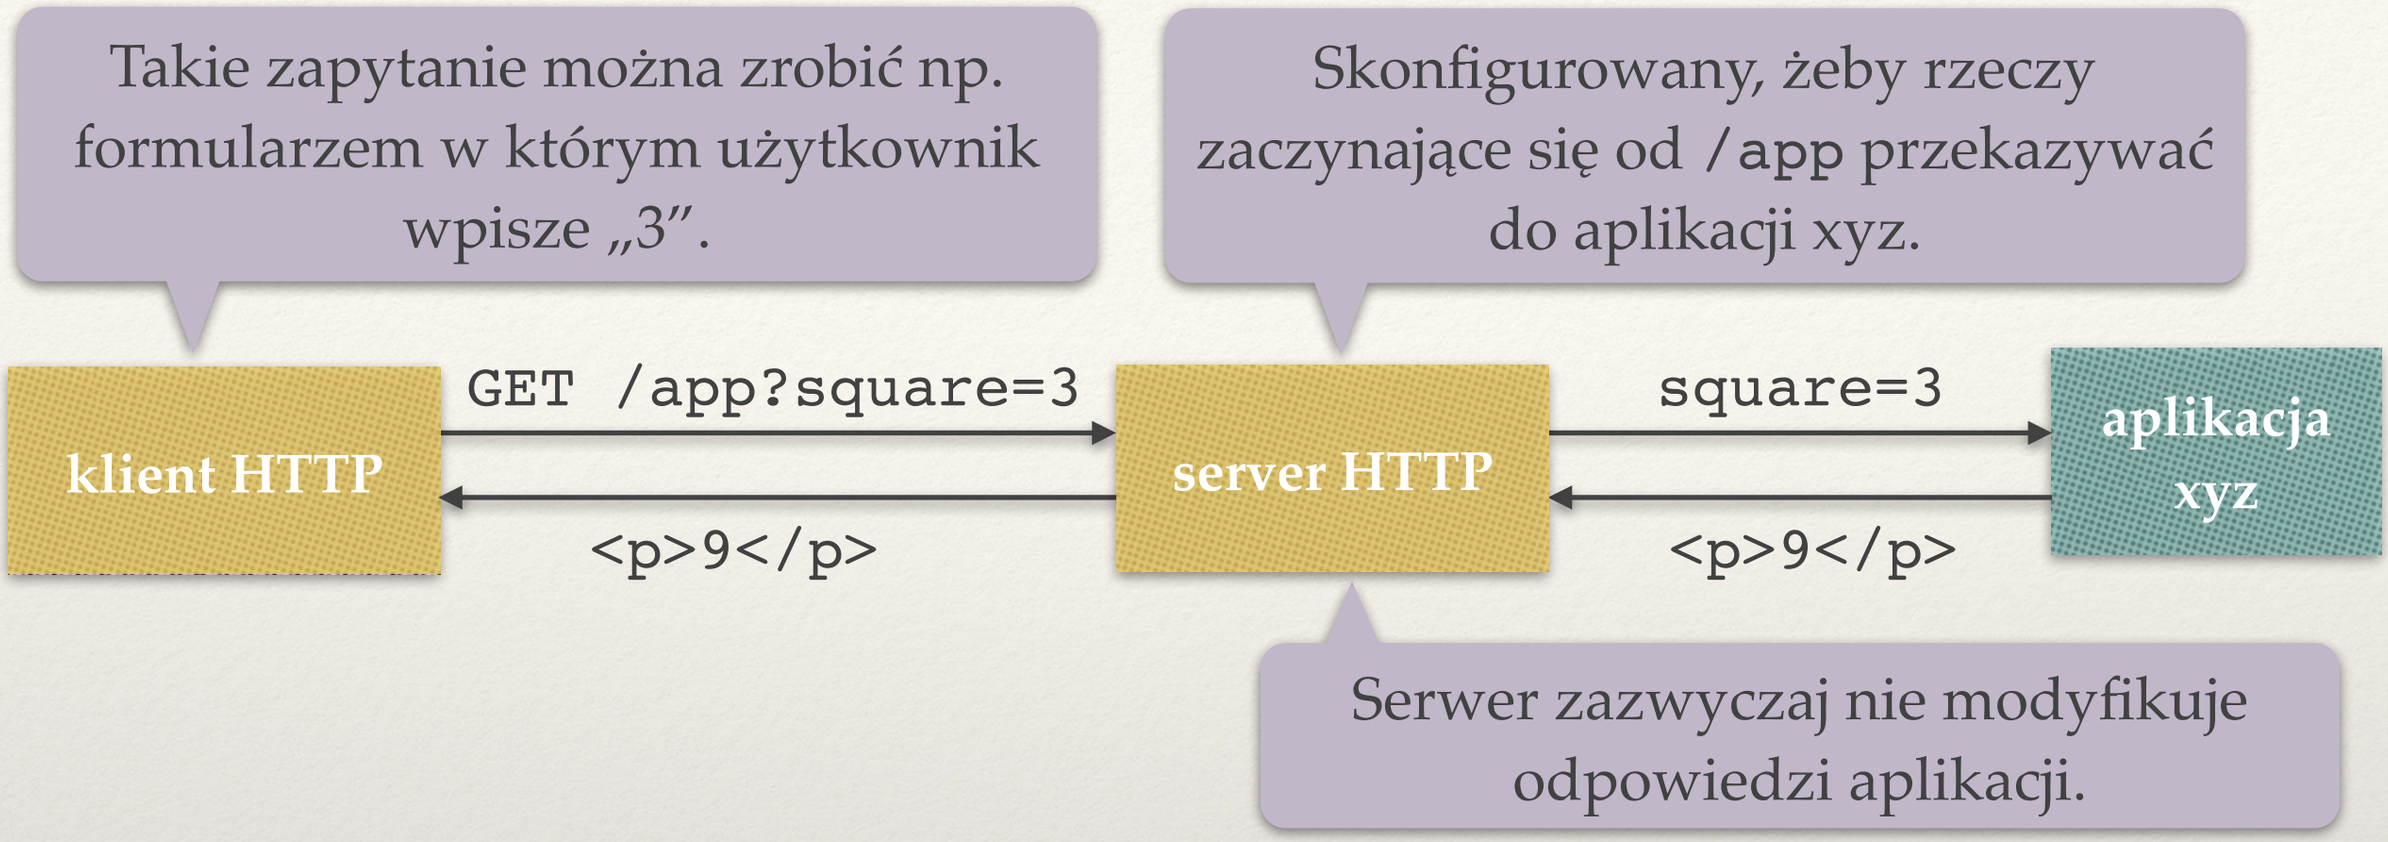

Komunikacja między serwerem a aplikacją:

- Opcja 1: każdorazowe uruchamianie xyz (standard CGI, mało wydajne).
- Opcja 2: aplikacja jest modułem serwera (w PHP, Pythonie, …).
- Opcja 3: aplikacja po prostu rozumie HTTP.
  - Serwer HTTP jest tylko pośrednikiem + serwuje statyczne strony.

Cookie


klient HTTP
GET /app?set_name=Marcin
server HTTP
aplikacja xyz

Cookie

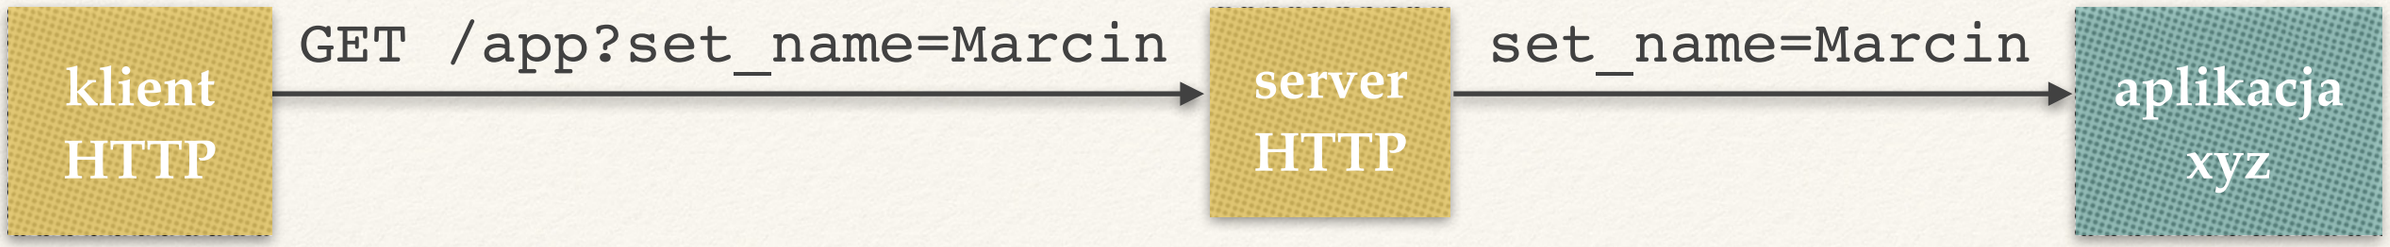
klient HTTP
GET /app?set_name=Marcin
server HTTP
set_name=Marcin
aplikacja xyz

Cookie


klient HTTP
GET /app?set_name=Marcin
server HTTP
set_name=Marcin
aplikacja xyz
Set-Cookie: sID=ba…3953
OK
Zapamiętuje informacje o użytkowniku pod identyfikatorem sesji ba...3953.

Cookie


klient HTTP
GET /app?set_name=Marcin
server HTTP
set_name=Marcin
aplikacja xyz
Set-Cookie: sID=ba…3953
OK
Zapamiętuje informacje o użytkowniku pod identyfikatorem sesji ba...3953.

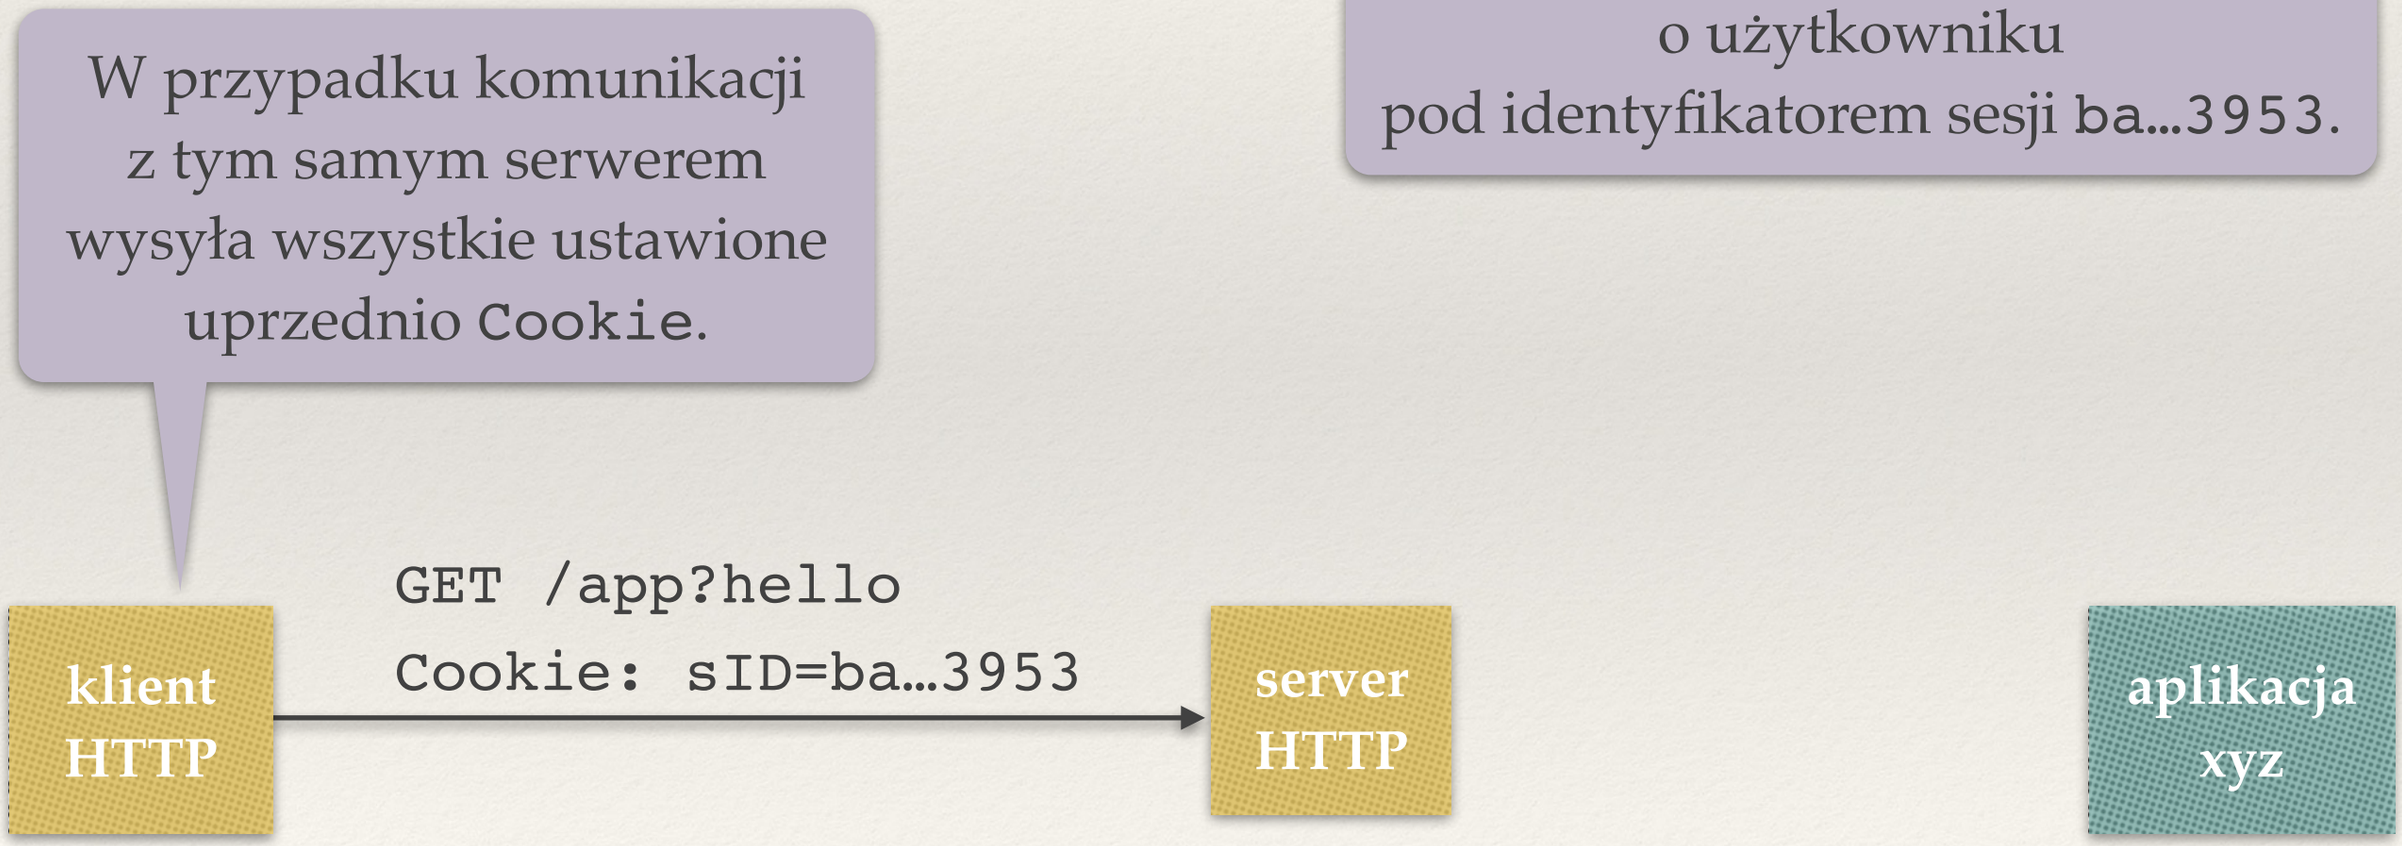
W przypadku komunikacji z tym samym serwerem wysyła wszystkie ustawione uprzednio Cookie.
klient HTTP
GET /app?hello
Cookie: sID=ba…3953
server HTTP
aplikacja xyz

Cookie


klient HTTP
GET /app?set_name=Marcin
server HTTP
set_name=Marcin
aplikacja xyz
Set-Cookie: sID=ba…3953
OK
Zapamiętuje informacje o użytkowniku pod identyfikatorem sesji ba...3953.

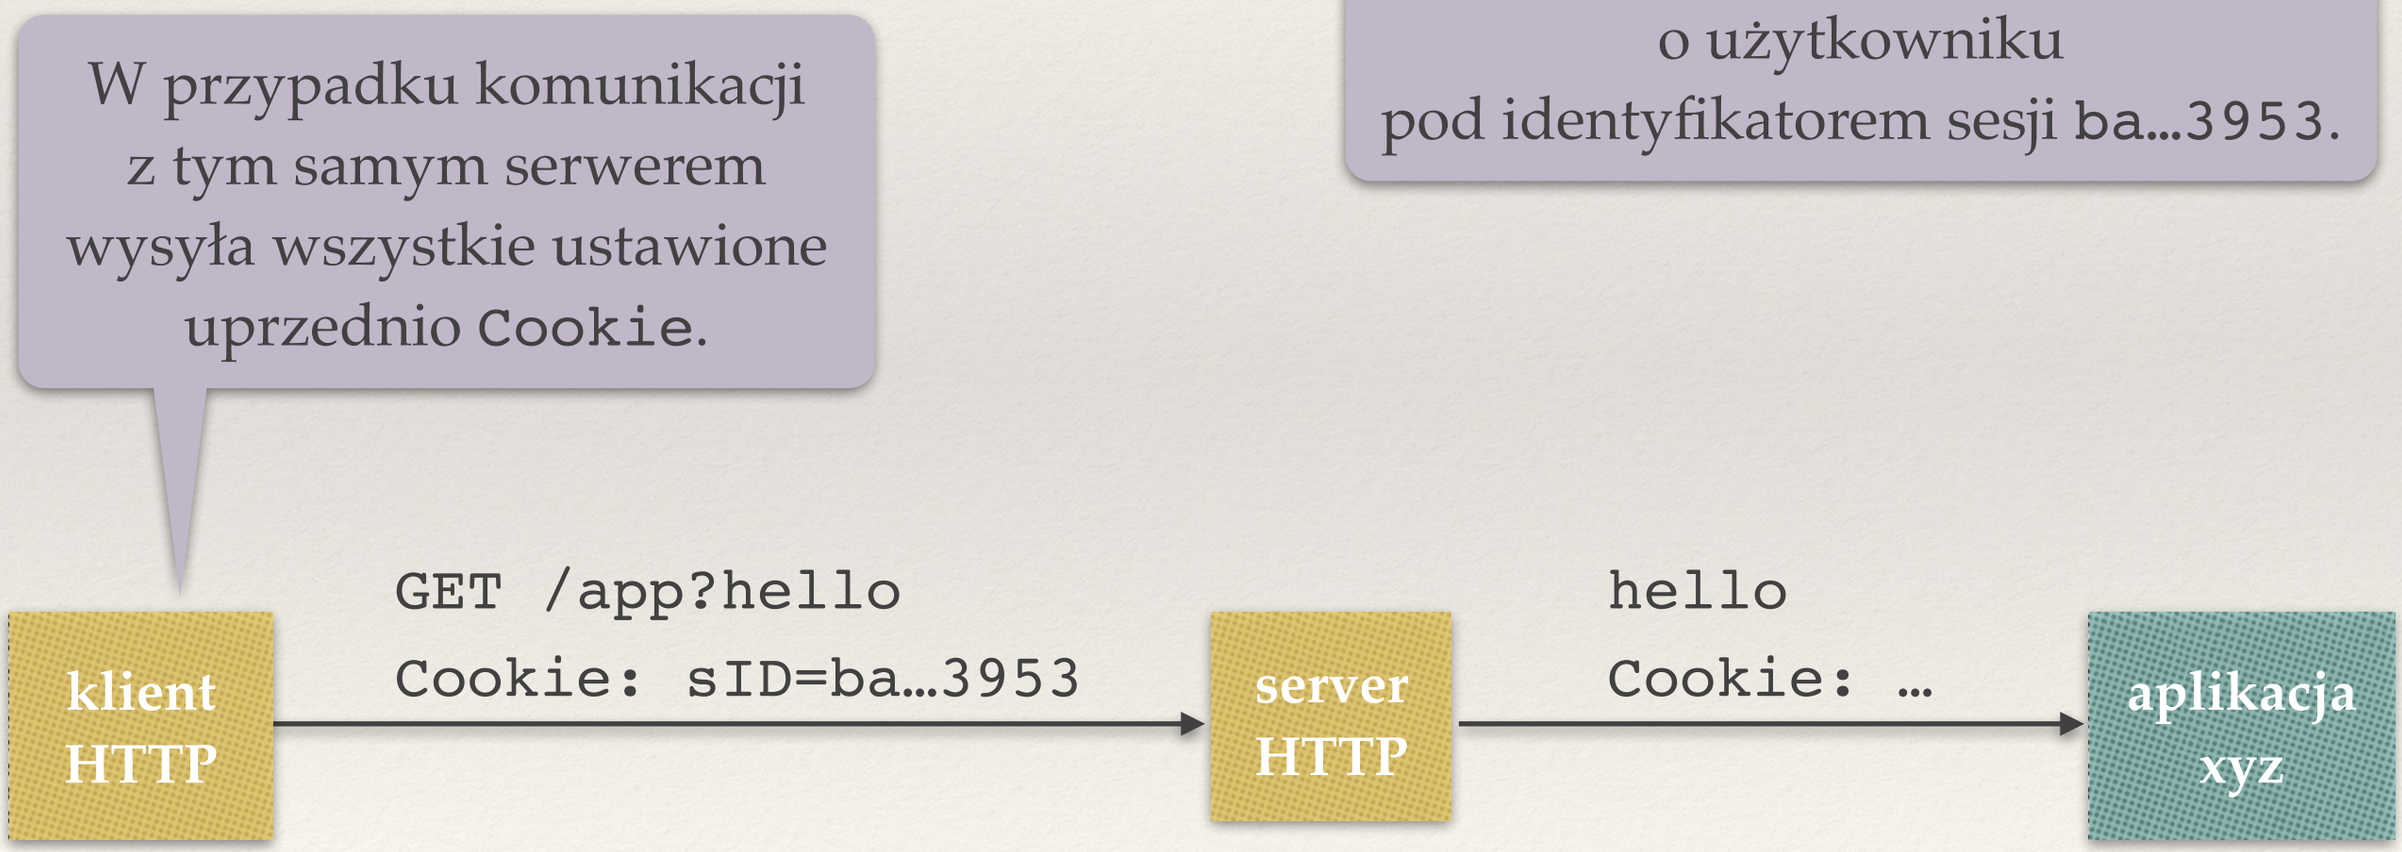
W przypadku komunikacji z tym samym serwerem wysyła wszystkie ustawione uprzednio Cookie.
klient HTTP
GET /app?hello
Cookie: sID=ba…3953
server HTTP
hello
Cookie: …
aplikacja xyz

Cookie


klient HTTP
GET /app?set_name=Marcin
server HTTP
set_name=Marcin
aplikacja xyz
Set-Cookie: sID=ba…3953
OK
Zapamiętuje informacje o użytkowniku pod identyfikatorem sesji ba...3953.

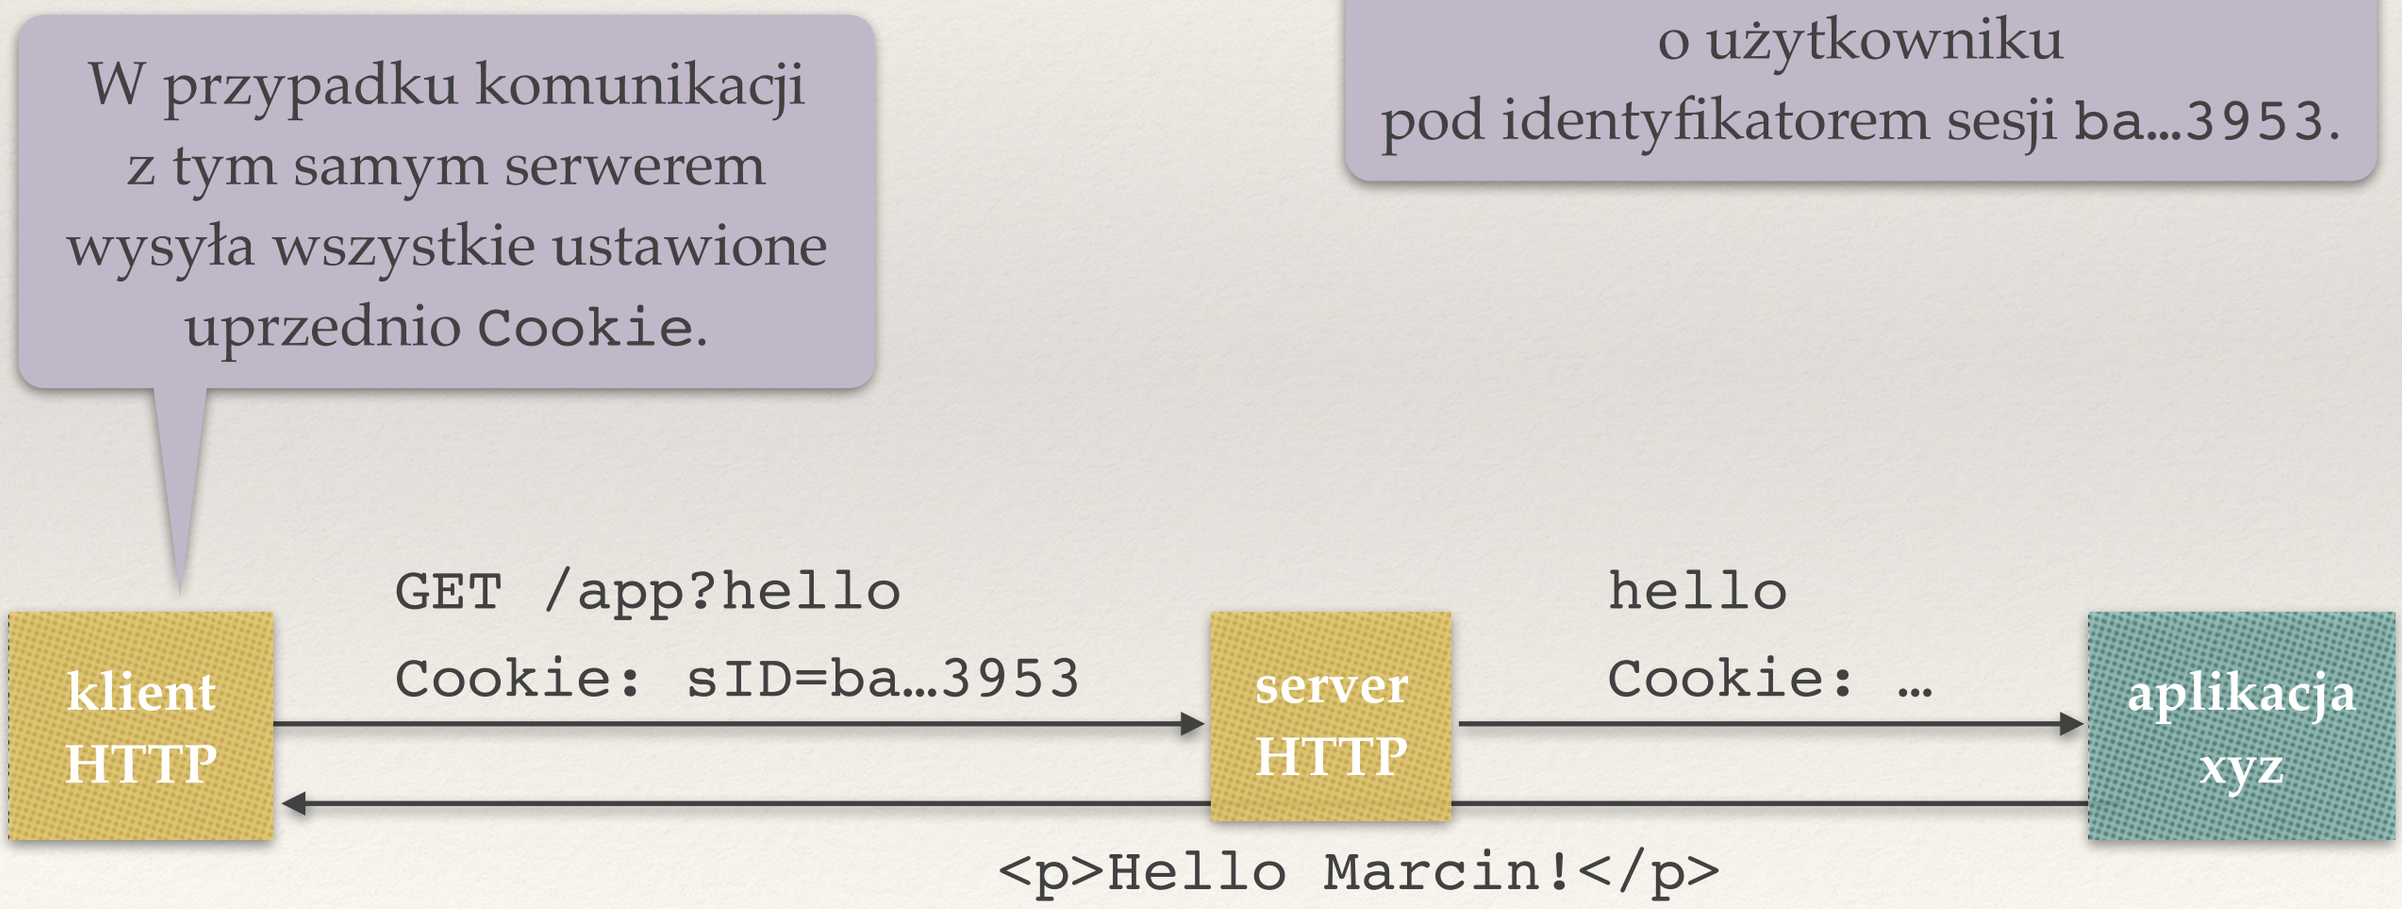
W przypadku komunikacji z tym samym serwerem wysyła wszystkie ustawione uprzednio Cookie.
klient HTTP
GET /app?hello
Cookie: sID=ba…3953
server HTTP
hello
Cookie: …
aplikacja xyz
Hello Marcin!

Formularze

- **Wysyłanie metodą GET.**
  - Przeglądarka pobiera stronę `http://domena/program?par1=val1&par2=val2`.
  - Serwer WWW uruchamia `program` i przekazuje mu parametry, `program` generuje odpowiedź (np. HTML).
  - Problem: nie powinno się tak przekazywać haseł. (Dlaczego?)
  - Problem: ograniczenie na rozmiar przekazywanych danych.

- **Wysyłanie metodą POST.**
  - Przeglądarka wysyła żądanie `POST` o stronę `http://domena/program`.
  - W **treści żądania** (nie w nagłówku) znajduje się `par1=val1&par2=val2`.
  - Można w ten sposób wysyłać też pliki do serwera.

JavaScript

- Część dynamiki strony WWW odbywa się wyłącznie po stronie klienta, bez komunikacji z serwerem.

- **Javascript:** język zintegrowany z HTML, mający łatwy dostęp do struktury dokumentu i mogący ją modyfikować.
  - Wzbogacany przez różne biblioteki (React, Angular, …).
  - Może też sam wysyłać zapytania HTTP do serwera.

Poprawianie wydajności

Połączenia trwałe (1)

- **Do HTTP 1.0.**
  - Każda para żądanie-odpowiedź w osobnym połączeniu TCP.
  - Nawiązywanie połączenia TCP → duży narzut czasowy.
  - Kończenie połączenia TCP → narzut czasowy + dużo połączeń w stanie `TIME_WAIT`.
- **Od HTTP 1.1.**
  - Wiele żądań i odpowiedzi w jednym połączeniu TCP.
  - Połączenie domyślnie otwarte.
  - Zamknięcie połączenia po odpowiedzi na żądanie, w którym umieścimy wiersz `Connection: close`.

Połączenia trwałe (2)

Przykład:

- Pobieranie strony HTML + 10 obrazków.
- Każdy obiekt mieści się w jednym segmencie TCP.
- Czas propagacji: 50 ms.
- Czas nadawania (pełnego) segmentu z danymi: 10 ms.
- Czas nadawania segmentu kontrolnego TCP lub segmentu z zapytaniem HTTP: 0 ms.

Połączenia trwałe (3)

HTTP/1.0 (bez połączeń trwałych).

- Otrzymanie strony HTML: 210 ms.
- Pobieranie każdego z obrazków: kolejne: 210 ms.
- Usprawnienie: dwa równoległe połączenia do serwera
  → pobieranie 10 obrazków trwa
  $210\ \text{ms} \cdot (10/2) = 1050\ \text{ms}$.
- Całkowity czas: 210 + 1050 = 1260 ms.

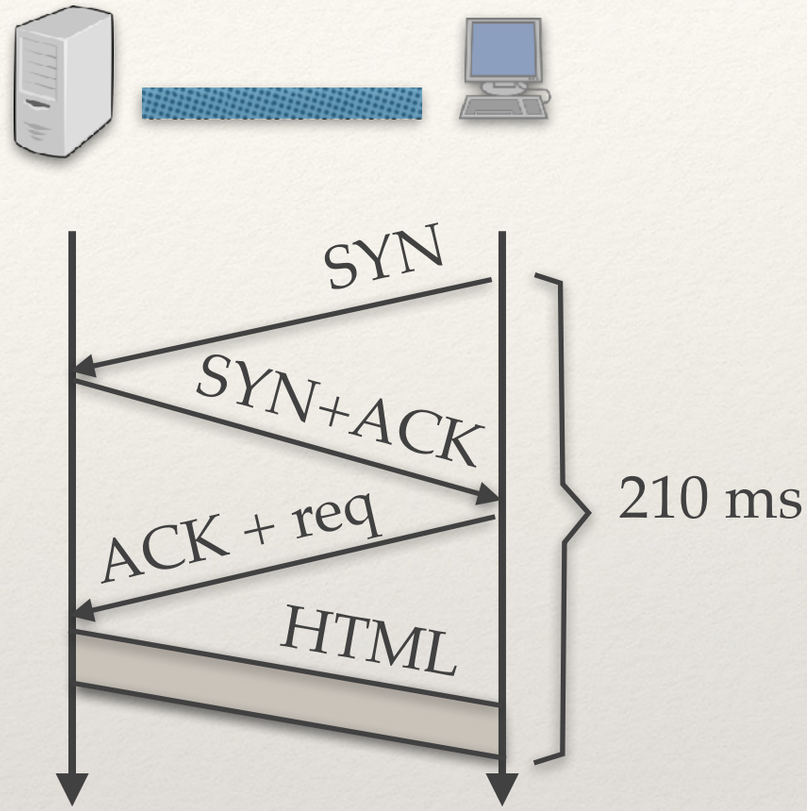

Połączenia trwałe (4)

HTTP/1.1 (połączenia trwałe).

- Otrzymanie strony HTML: 210 ms.
- Zapytanie o obrazek nr 1: 50 ms.
- Wysyłanie obrazków:
  $50 + 10 \cdot 10 = 150$ ms.
- Całkowity czas: $210 + 200 = 410$ ms.

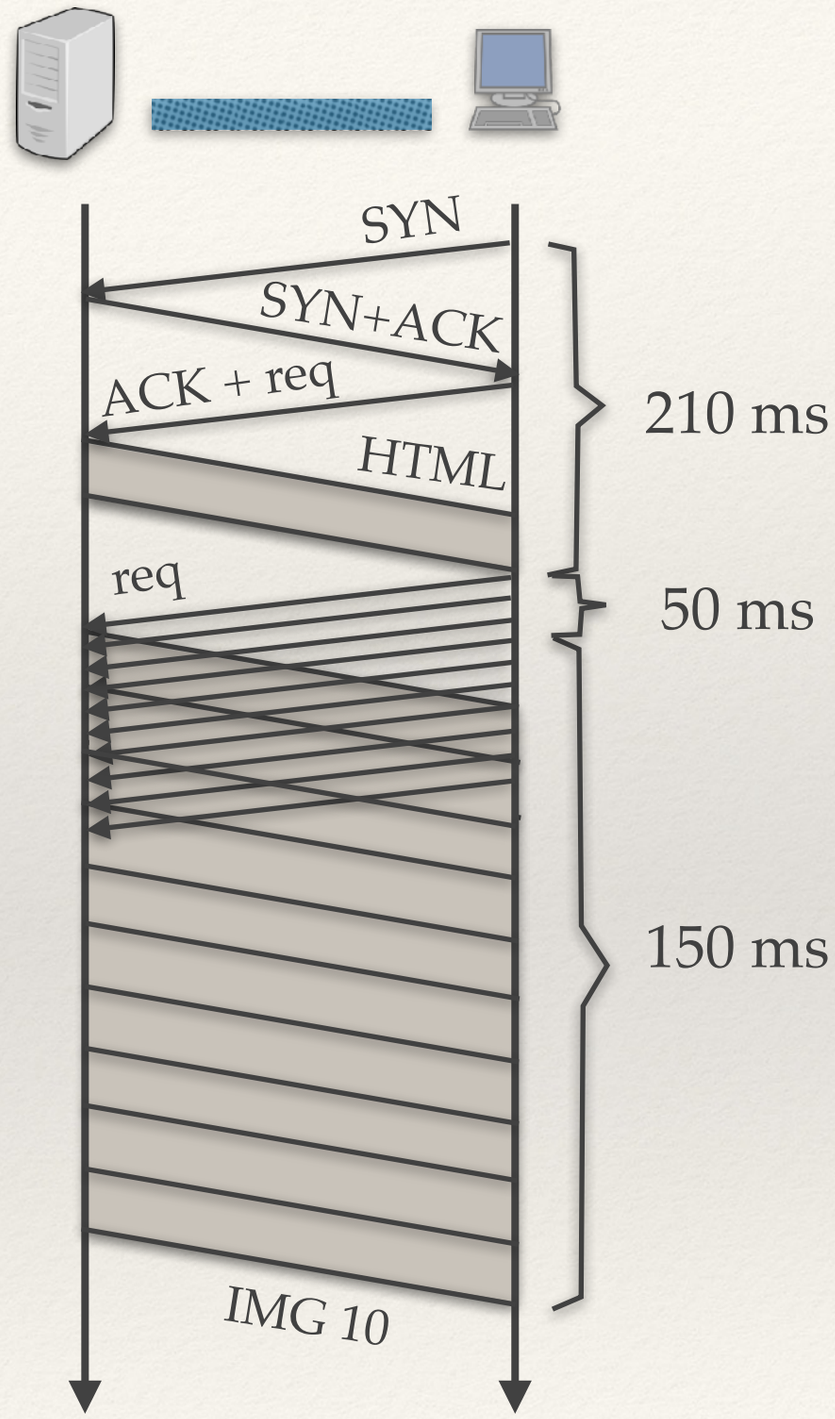

Połączenia trwałe (4)

HTTP/1.1 (połączenia trwałe).

- Otrzymanie strony HTML: 210 ms.
- Zapytanie o obrazek nr 1: 50 ms.
- Wysyłanie obrazków:
  $50 + 10 \cdot 10 = 150$ ms.
- Całkowity czas: $210 + 200 = 410$ ms.
- Niepotrzebne dodatkowe połączenia TCP.
- Jedno połączenie: okno TCP szybciej rośnie (kontrola przeciążenia).

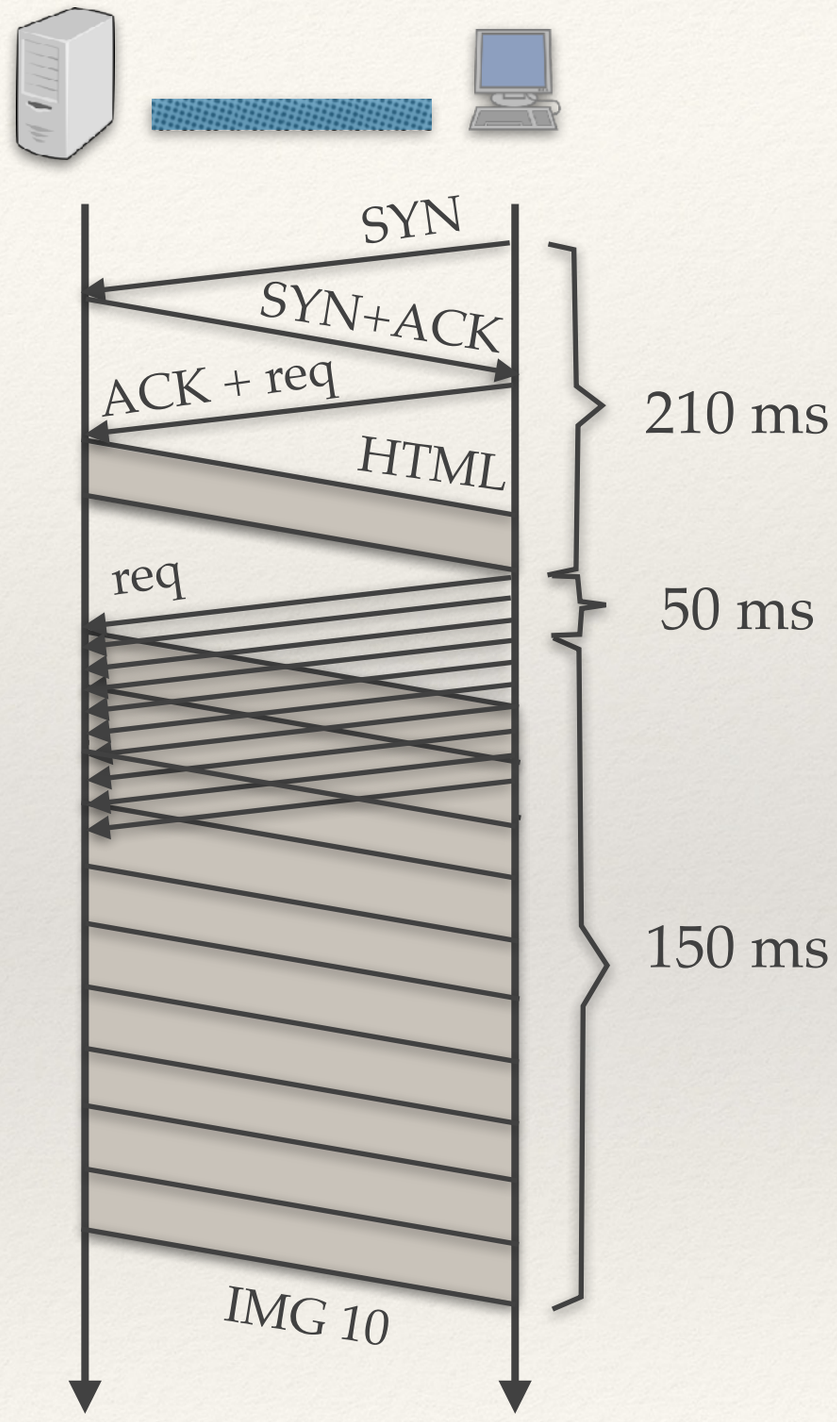

Zapytanie warunkowe GET

- W nagłówku podajemy:

```
If-Modified-Since: Wed, 20 Apr 2021 23:27:04 GMT
```

- Możliwe odpowiedzi:
  - `200 OK`
  - `304 Not Modified`

Pamięć podręczna w przeglądarce WWW

- Serwer może umieszczać w nagłówku odpowiedzi pola:
  - `Expires:` (do kiedy można trzymać dokument w pamięci podręcznej) → można całkowicie pominąć żądanie strony.
  - `Cache-Control: no-cache` (nigdy nie trzymaj w pamięci podręcznej)

Serwer proxy (1)

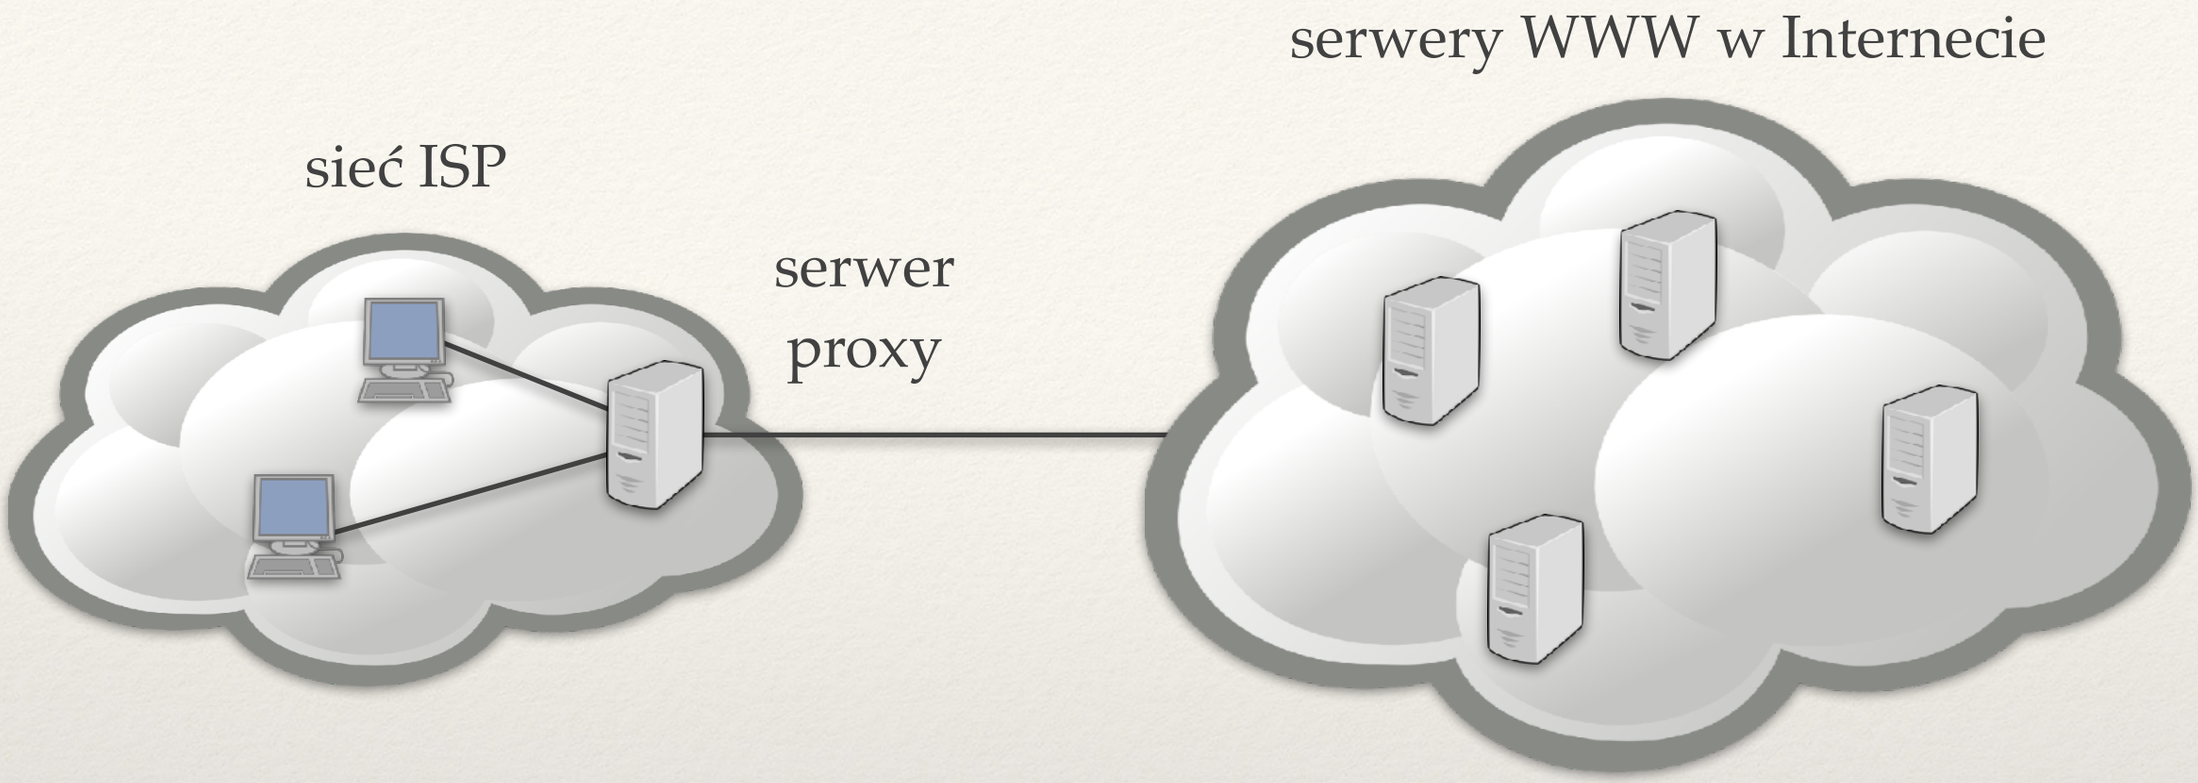

- Przeglądarka wysyła zapytanie HTTP do serwera proxy.
- Proxy w razie potrzeby łączy się z serwerem HTTP.
- Serwer proxy odpowiada używając stron przechowywanych w swojej pamięci podręcznej.
- W razie potrzeby przeglądarka może wymusić pominięcie proxy.

Serwer proxy (2)

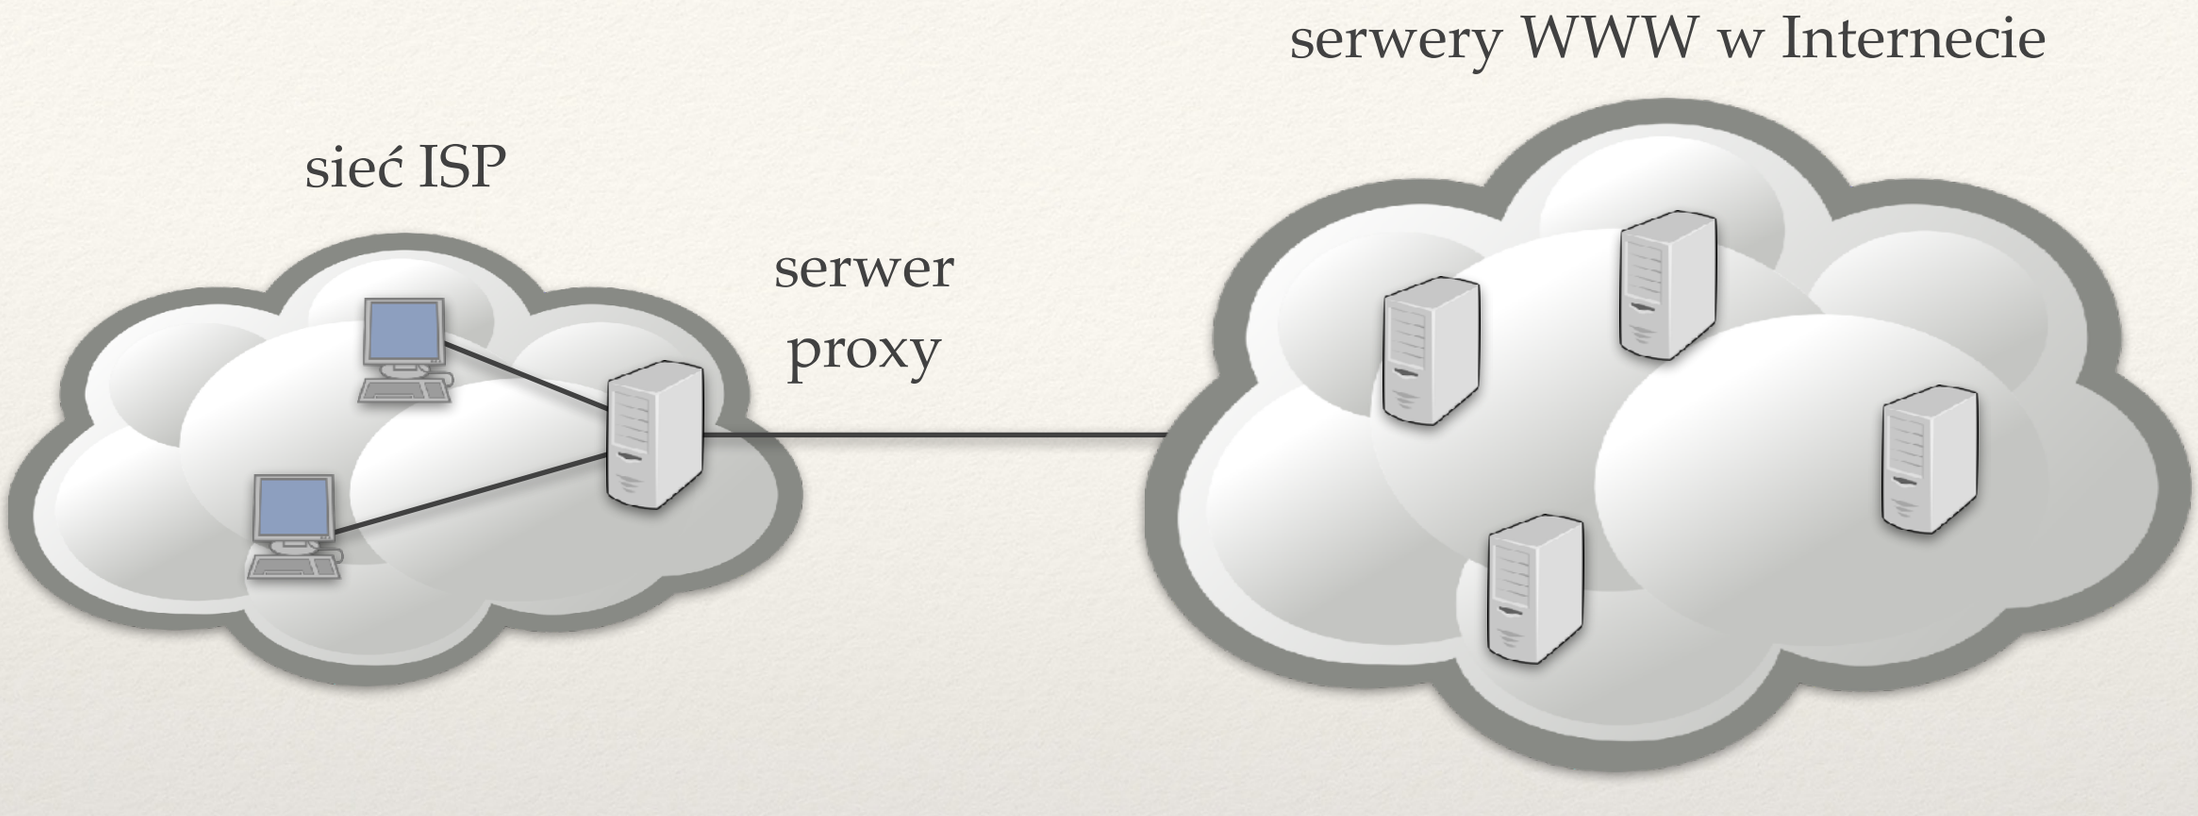

- Wpisywany w ustawieniach przeglądarki HTTP.
- Czasem wymuszany przez ISP (integrowany z routerem obsługującym ruch z danej sieci).
- Korzyści: głównie dla ISP (ograniczenie ilości danych).

Odwrotne proxy

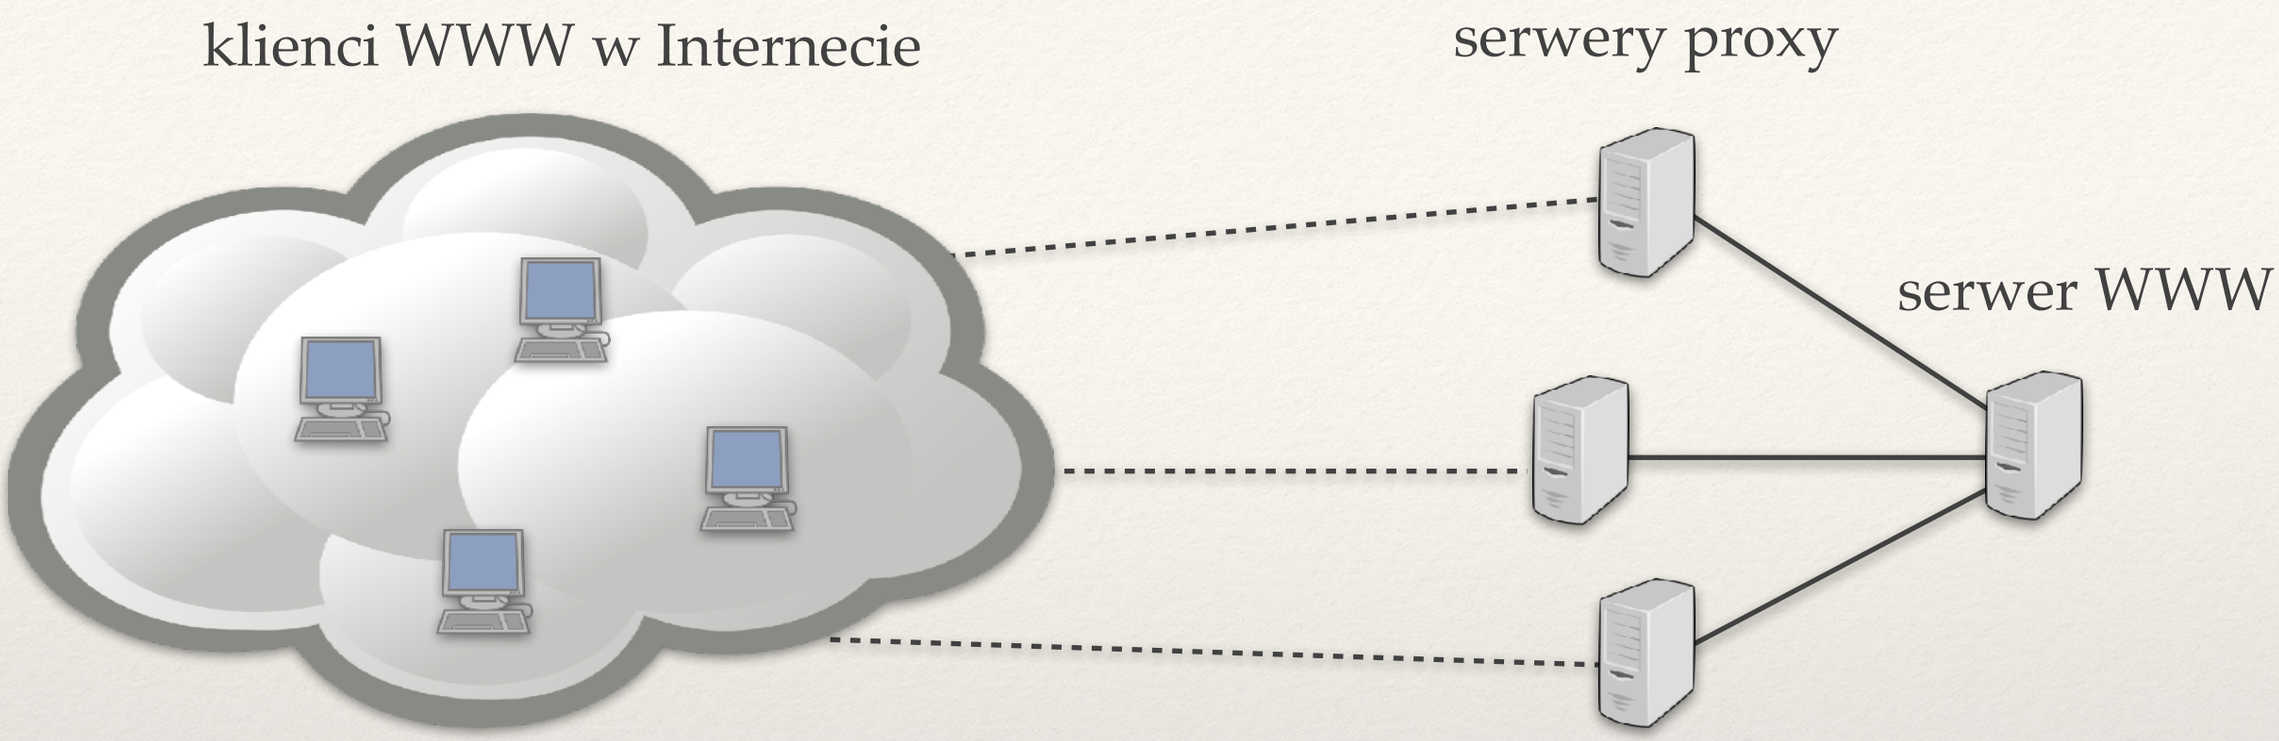

- Wykorzystywane przez dostawców treści (zmniejszają obciążenie serwera WWW.
- Zysk dla klienta i dostawcy treści.
- Ale: duże opóźnienie w przesyłaniu pakietów pomiędzy klientami i serwerami proxy.
- **Jak opłacalnie przysunąć serwery proxy do klientów?**

CDN (Content Distribution Networks)

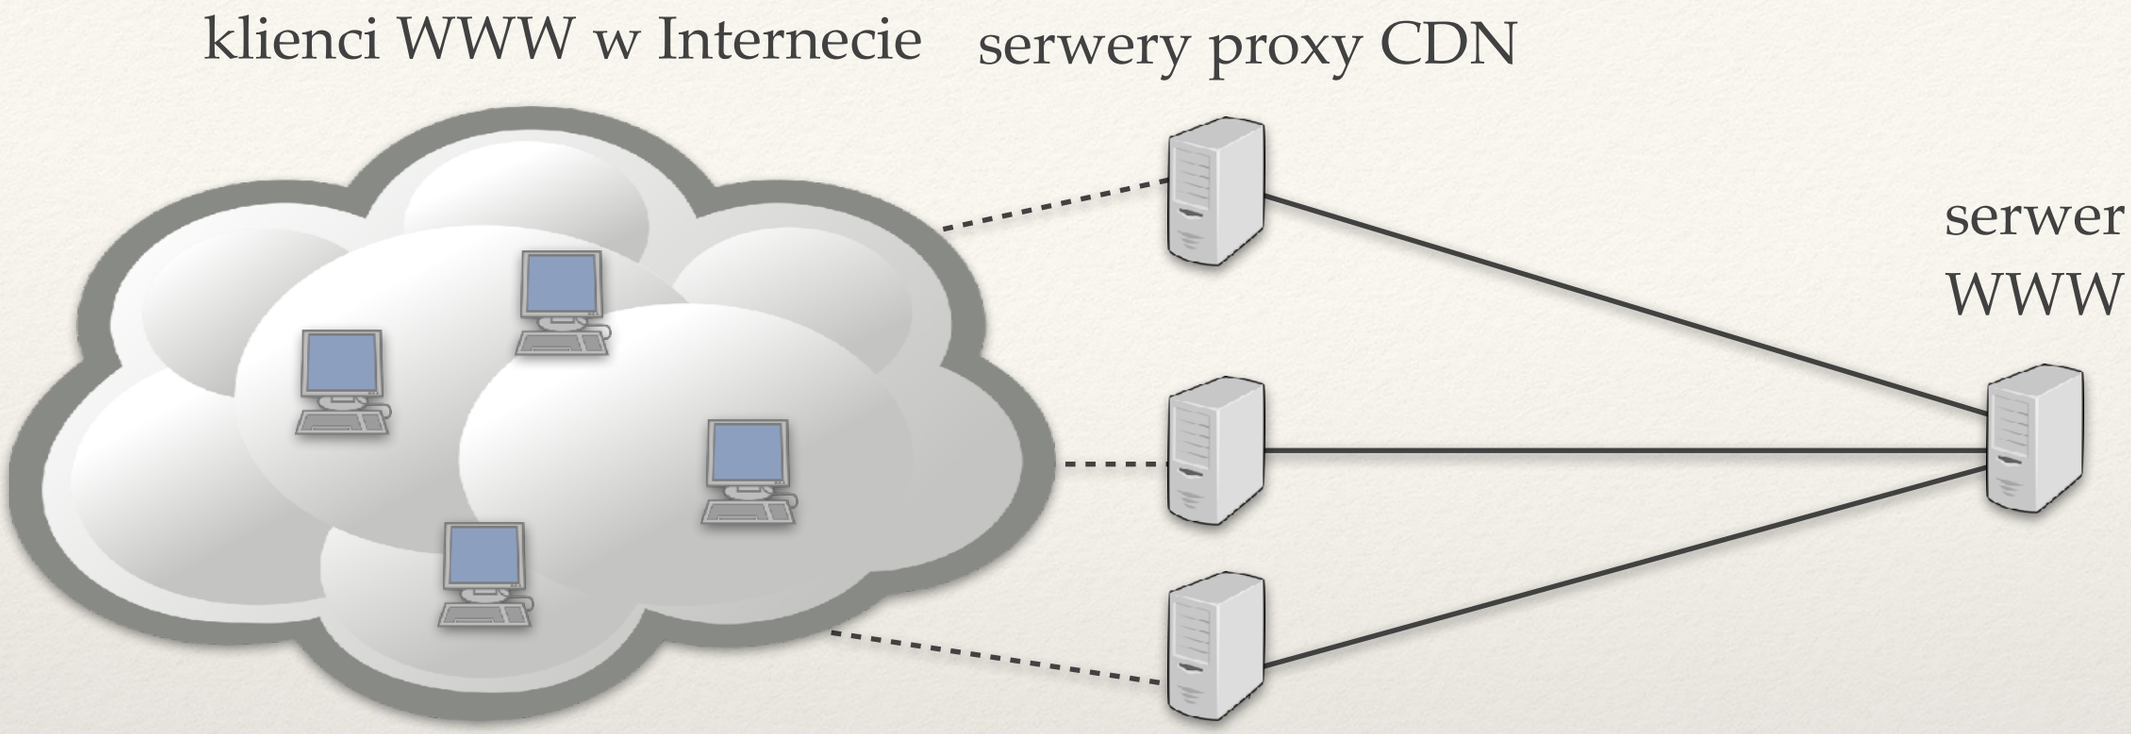

- Serwery proxy obsługiwane przez osobną organizację (obsługuje wiele serwerów WWW).
  - Cloudflare, Akamai, …
  - Setki tysięcy serwerów proxy.

- **Jak sprawić, żeby klient zamiast do serwera WWW trafiał do serwera proxy?**

CDN: znajdowanie serwera proxy

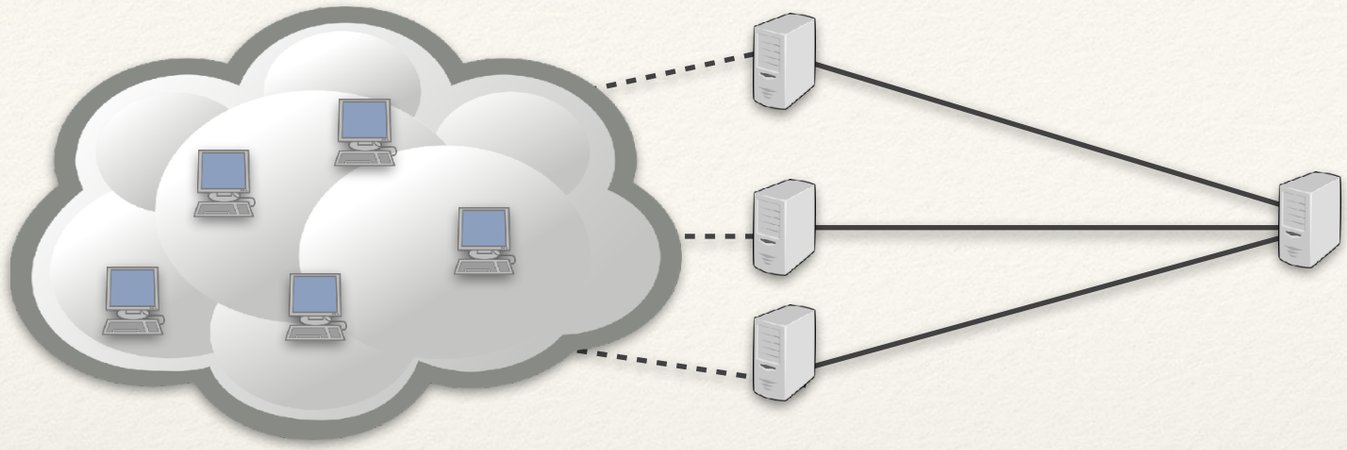

Jak skierować klienta do odpowiedniego (bliskiego) serwera CDN?

- Dawno temu: klient pobiera stronę z serwera WWW zawierającą (automatycznie generowane) URL-e do obrazków na serwerach proxy.
- Później: zamiast strony WWW klient dostaje przekierowanie do odpowiedniego serwera proxy (*HTTP redirect*).
- Współcześnie: za pomocą serwerów DNS (utrzymywanych przez CDN): zapytanie o daną domenę zwraca adres IP serwera proxy.

Dygresja: anonimizujące serwery proxy

- **Serwer proxy dodaje do żądania HTTP dodatkowe pola.**
  - `X-Forwarded-For:` adres IP.
  - `Via:` adres IP proxy.
- **Anonimizujące serwery proxy:**
  - Nie dodają takich nagłówków.
  - Zwykle płatne.

HTTP jako „warstwa transportowa”

REST

- Pisanie poprawnych programów korzystających z TCP jest niełatwe.
- Jak wykorzystać HTTP do przesyłania danych?
- Testowego klienta (przeglądarkę www) mamy za darmo.

- **REST**
  - Zautomatyzowany dostęp do niektórych serwisów WWW (eBay, Amazon, Twitter, …).
  - REST (*Representational State Transfer*) tworzenie usługi sieciowej wykorzystując metody (`GET`, `PUT`, `POST`, `DELETE`) protokołu HTTP.
  - REST nie jest standardem, raczej filozofią.
  - Łatwy do zautomatyzowania, czytelny dla człowieka.

Przesyłanie nieinteraktywnego video

Współcześnie video enkapsulowane jako dane protokołu HTTP.

- DASH = Dynamic Adaptive Streaming over HTTP.
  - Youtube, Netflix, HBO, Amazon Prime, …
- HLS = HTTP Live Streaming.
  - Twitch, HBO, Apple TV, …
- Wykorzystują pola `Range: bytes=xxx-yyy` w nagłówku zapytania HTTP.

HTTP/2 i HTTP/3

HTTP/2

- Binarny protokół.
- Kolejkowanie żądań (*pipelining*, obecny już w HTTP/1.1)
  + przesyłanie odpowiedzi w innej kolejności niż żądania.
- Server push: wysyłanie odpowiedzi na niezadane zapytania.
- Usuwanie powtarzających się nagłówków.
- Kompresja.
- Obowiązkowe szyfrowanie (TLS ≥ 1.2).

Protokoły w Internecie

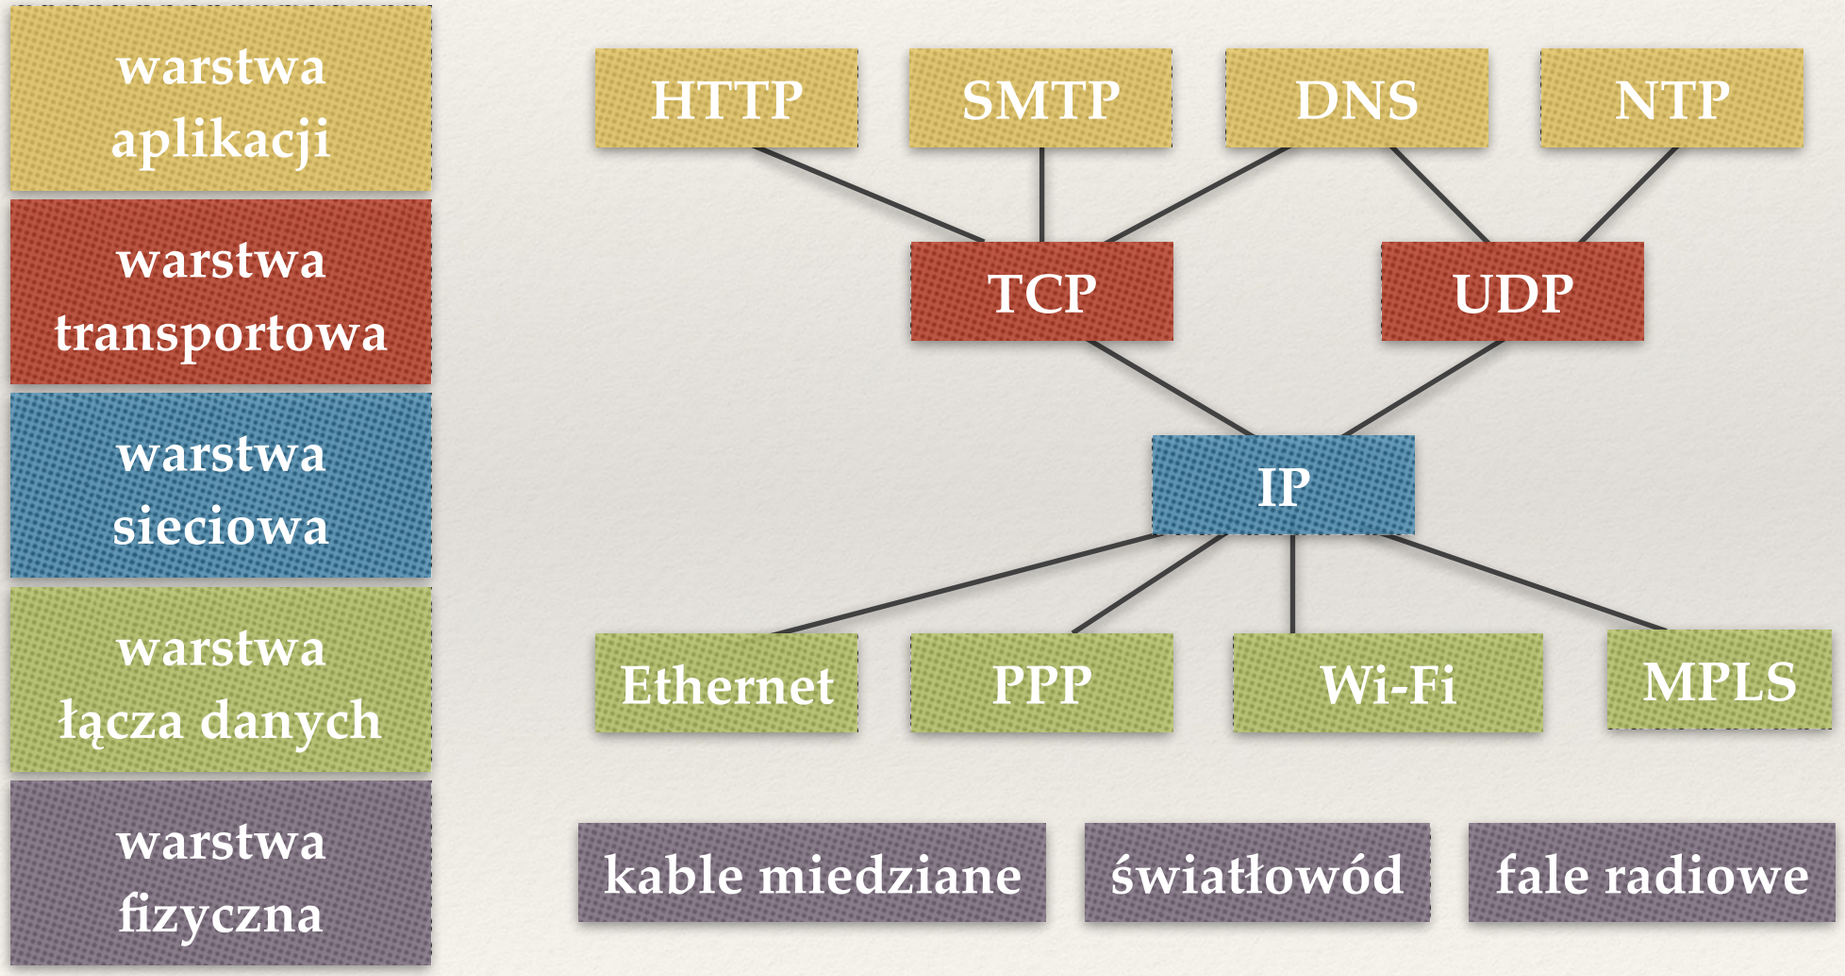

Protokoły w Internecie (dokładniej)

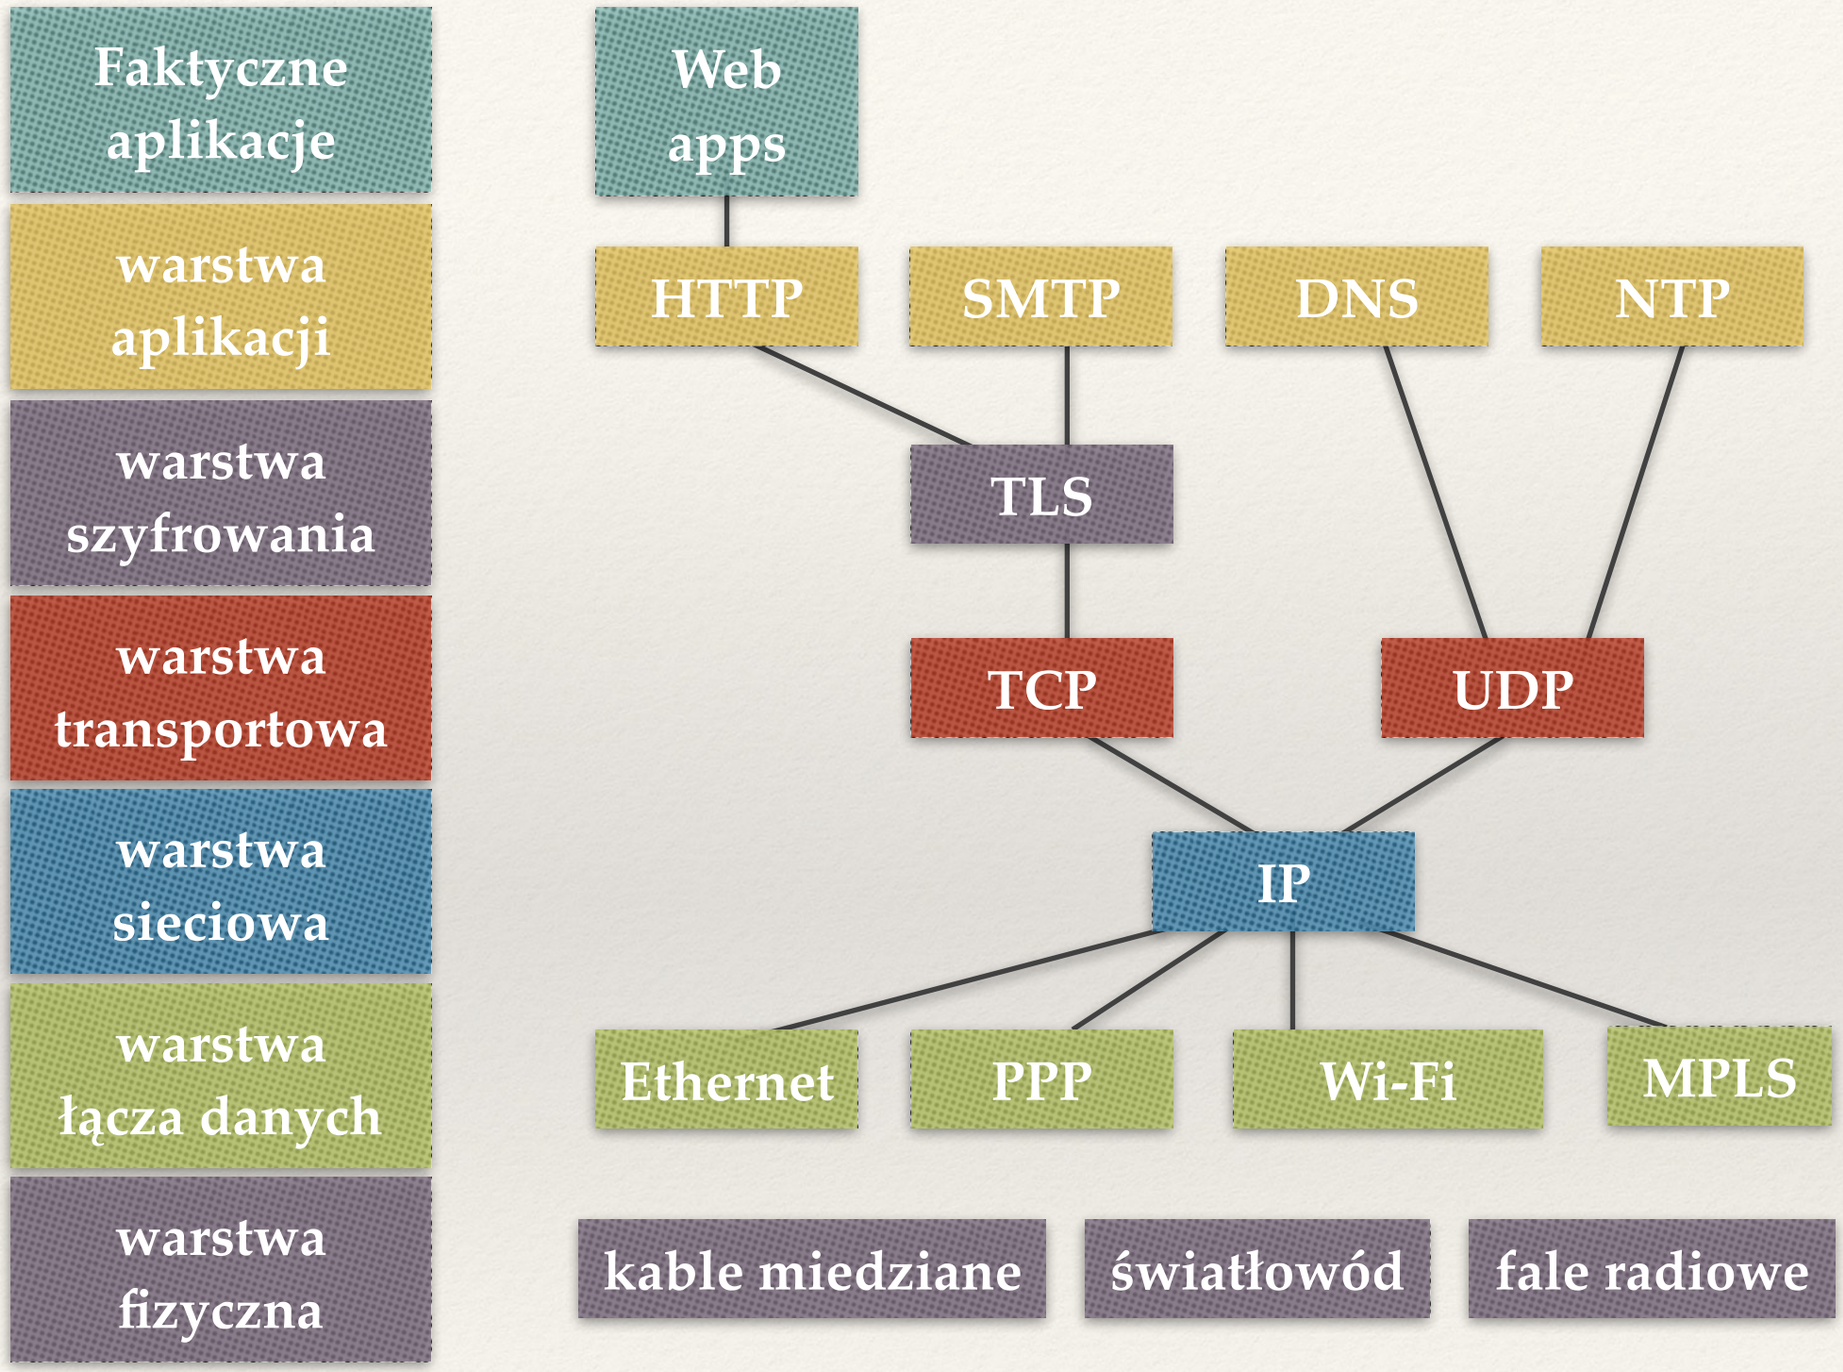

Dominująca technologia

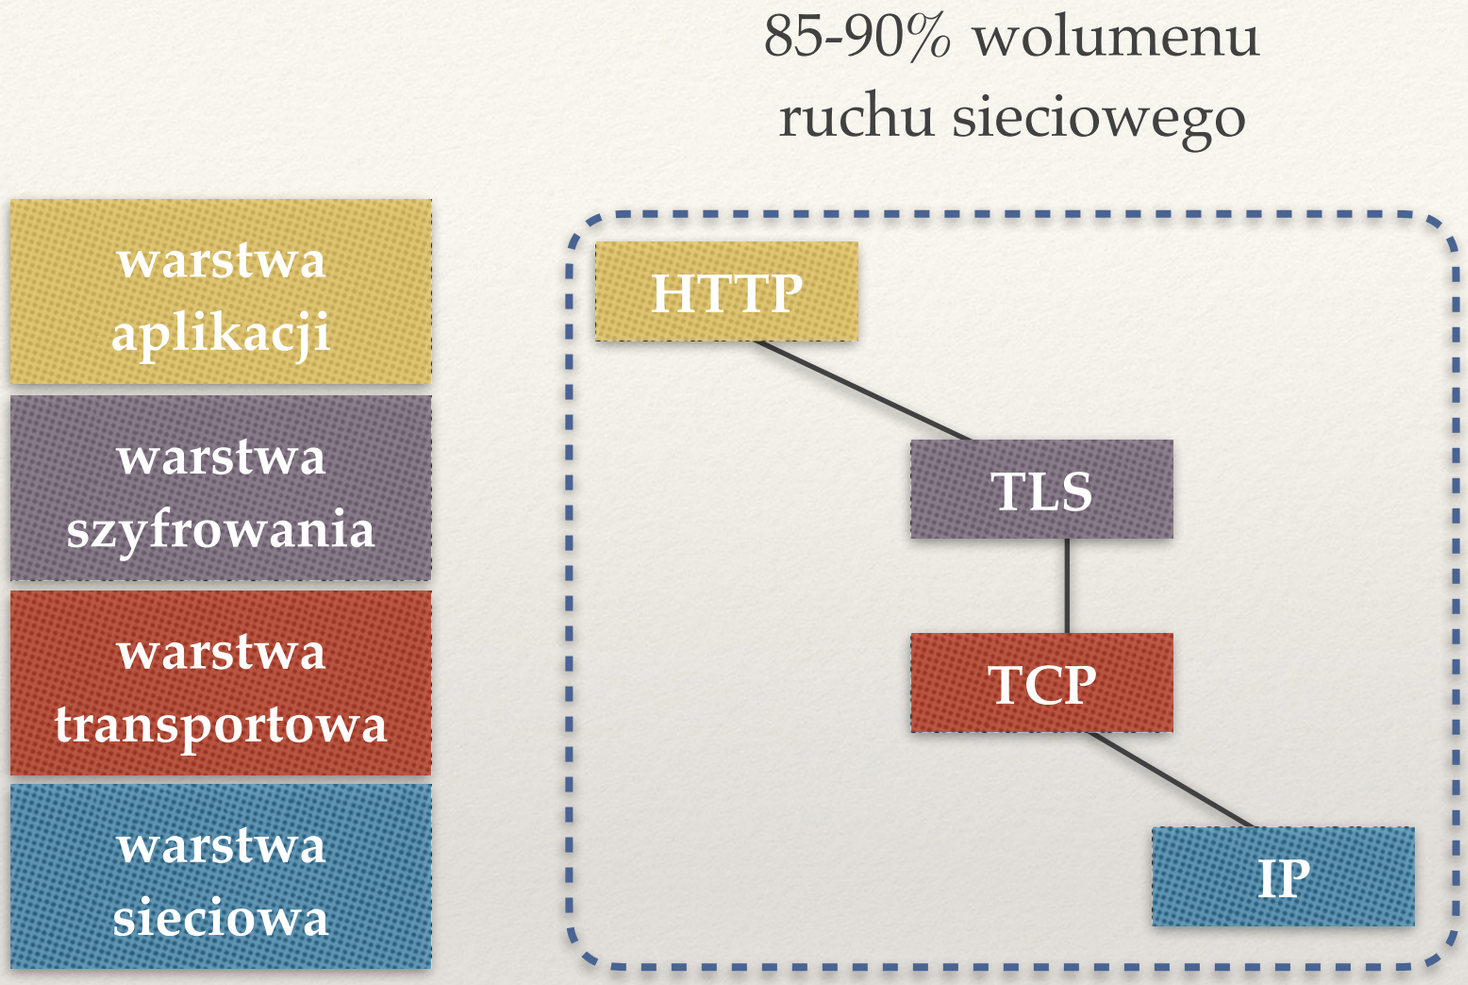

Model warstwowy

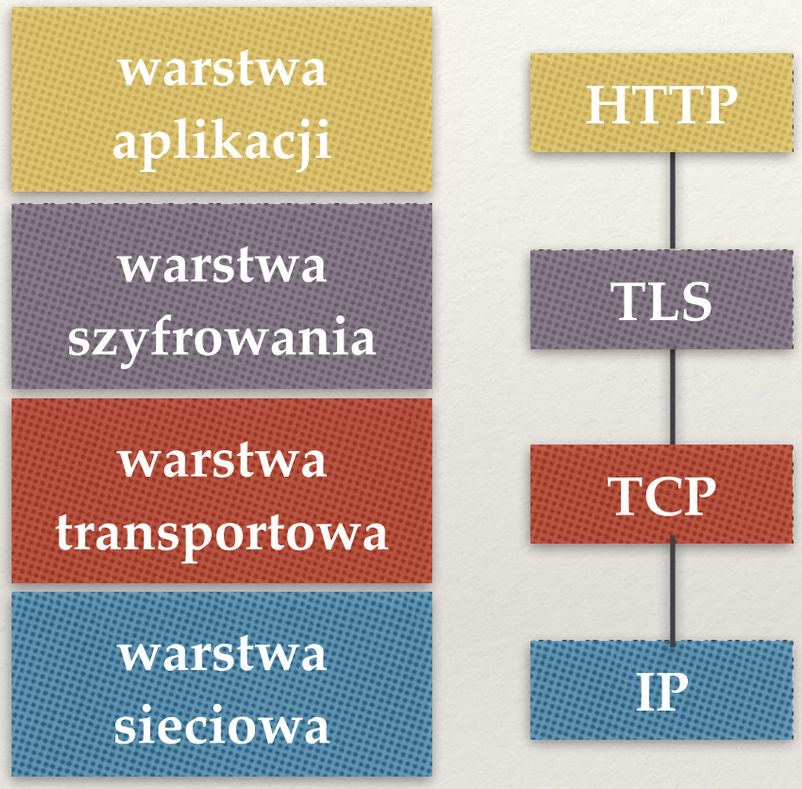

Dlaczego mamy model warstwowy?

- Względy historyczne: różne warstwy powstawały w różnych latach.
- Warstwy abstrakcji i podział zadań (np. powyżej warstwy transportowej nie musimy się przejmować niezawodnością dostarczania i przeciążeniem sieci/odbiorcy).

Problem 1: trzy nawiązywania połączenia

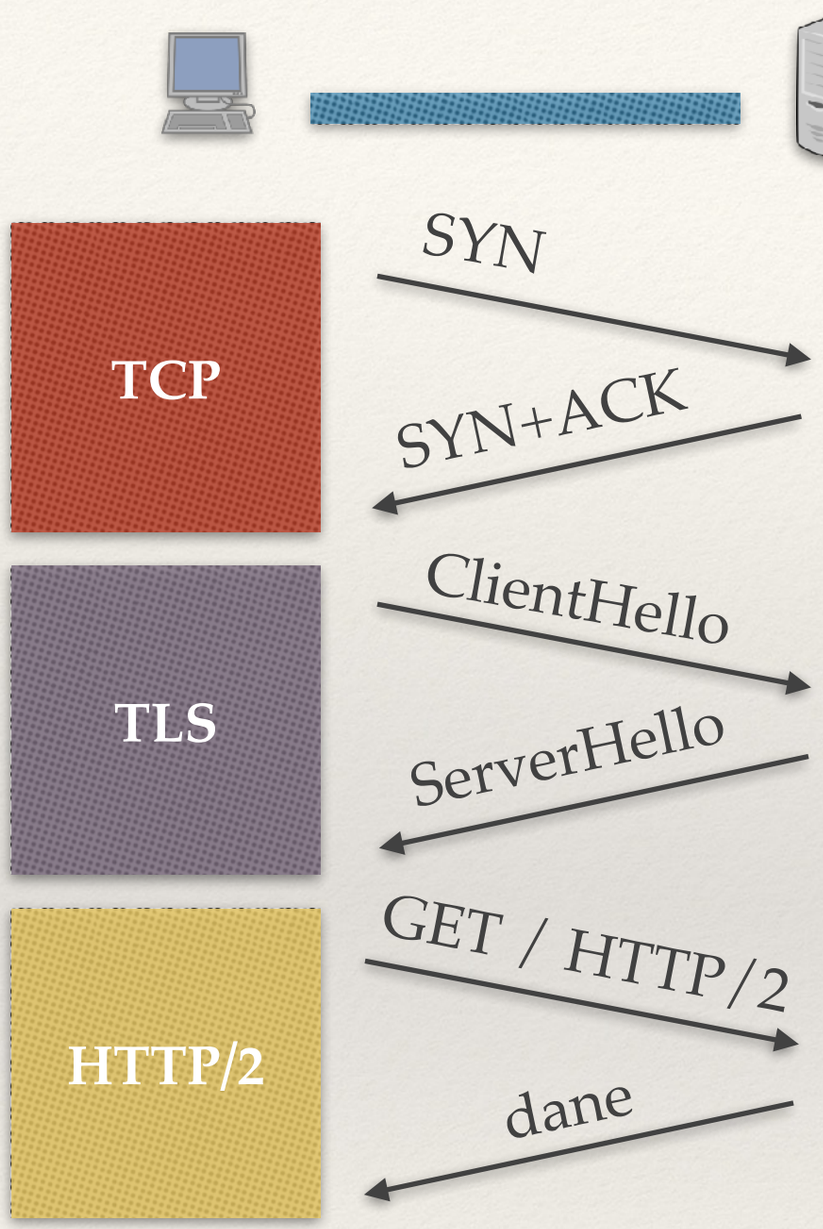

3 x RTT zanim klient zobaczy początek danych.

- Jeśli jest to pierwsze połączenie z danym serwerem, to może trwać jeszcze dłużej (wymiana kluczy kryptograficznych w TLS).

Problem 1: trzy nawiązywania połączenia

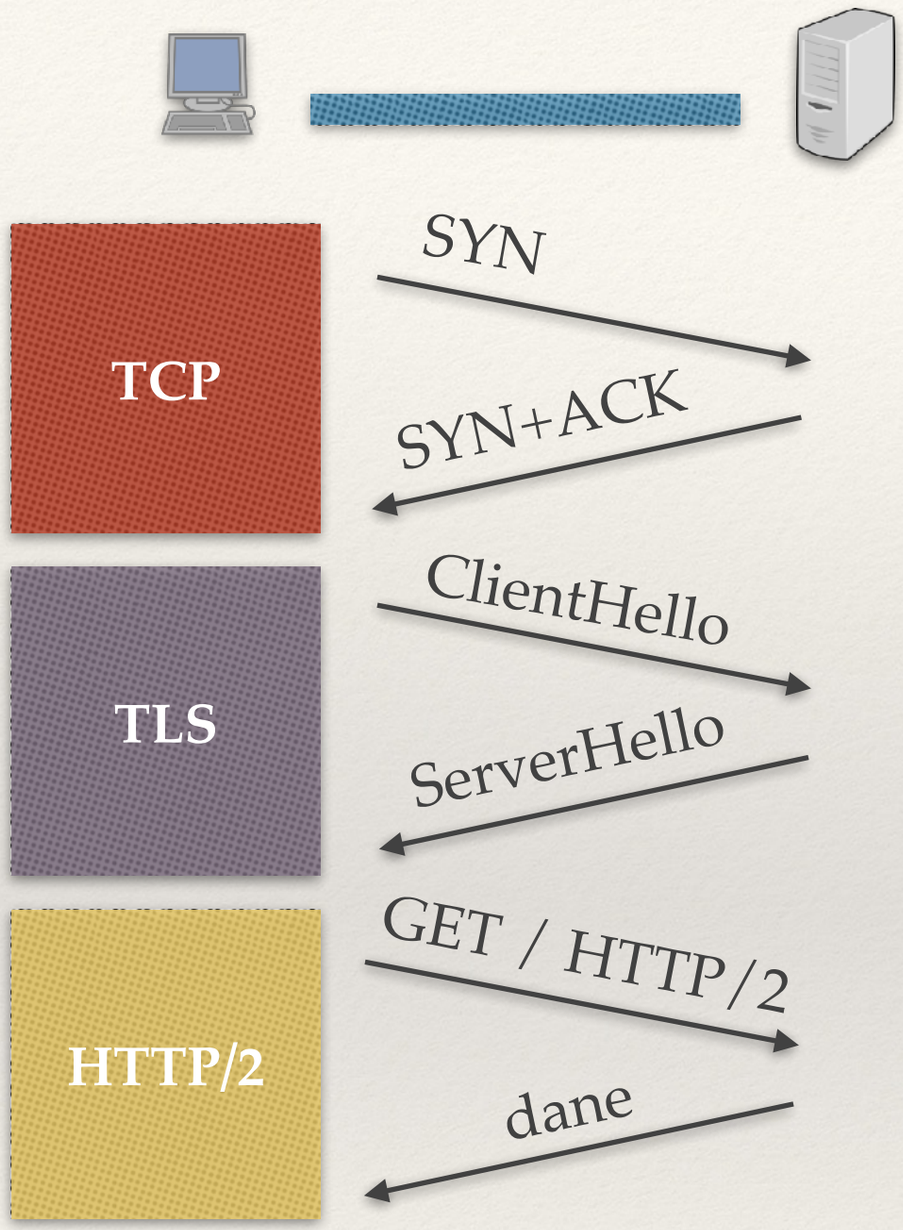

niemożliwe istotne zmniejszenie RTT (prędkość światła)

3 x RTT zanim klient zobaczy początek danych.

- Jeśli jest to pierwsze połączenie z danym serwerem, to może trwać jeszcze dłużej (wymiana kluczy kryptograficznych w TLS).

Problem 2: TCP utrzymuje kolejność

HTTP/2 wprowadza multiplexing zapytań i odpowiedzi:

- Może przesyłać odpowiedzi w innej kolejności niż pytania.
- Server push: wysyłanie odpowiedzi na niezadane zapytania.

Ale te informacje wkładane są w pojedynczy strumień danych, którym zarządza TCP. Przykład:

- Ginie segment zawierający mało istotny obrazek.
- Kolejne segmenty z innymi odpowiedziami HTTP docierają do klienta.
- Warstwa HTTP ich nie dostaje, bo TCP musi zrekonstruować strumień.

QUIC: nowy protokół transportowy

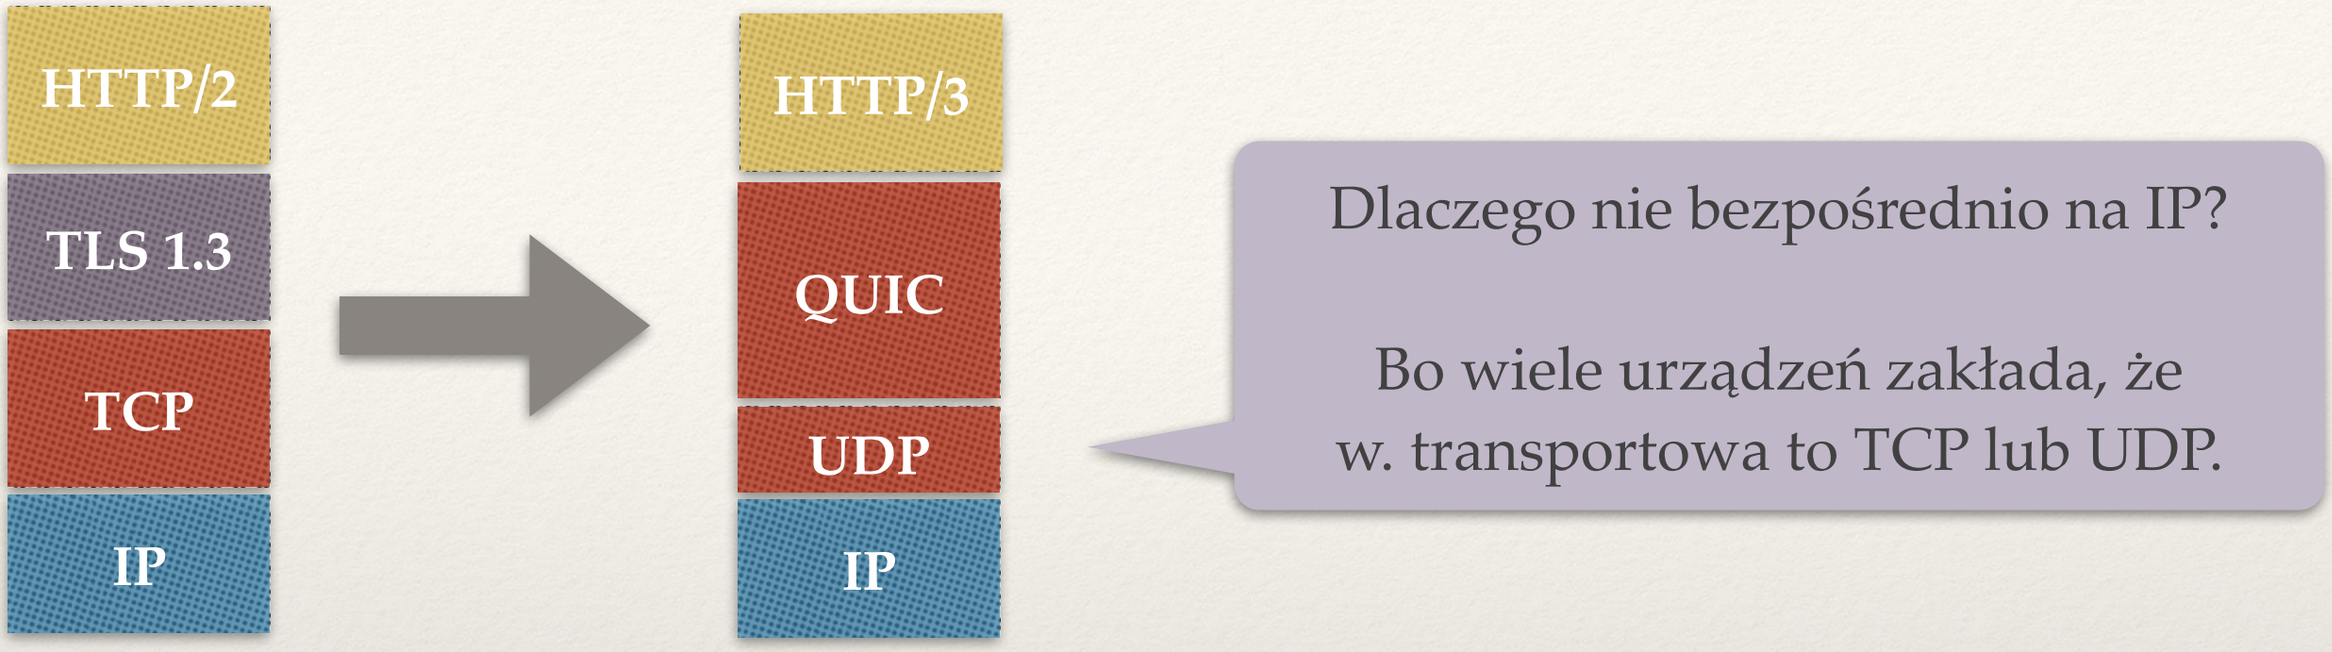

- Zintegrowane szyfrowanie TLS 1.3.
- Zaimplementowany w przestrzeni użytkownika (TCP jest w jądrze) → przewidywana szybsza ewolucja.
- HTTP/3 = QUIC + HTTP/2.

Połączenia

TCP + TLS + HTTP/2

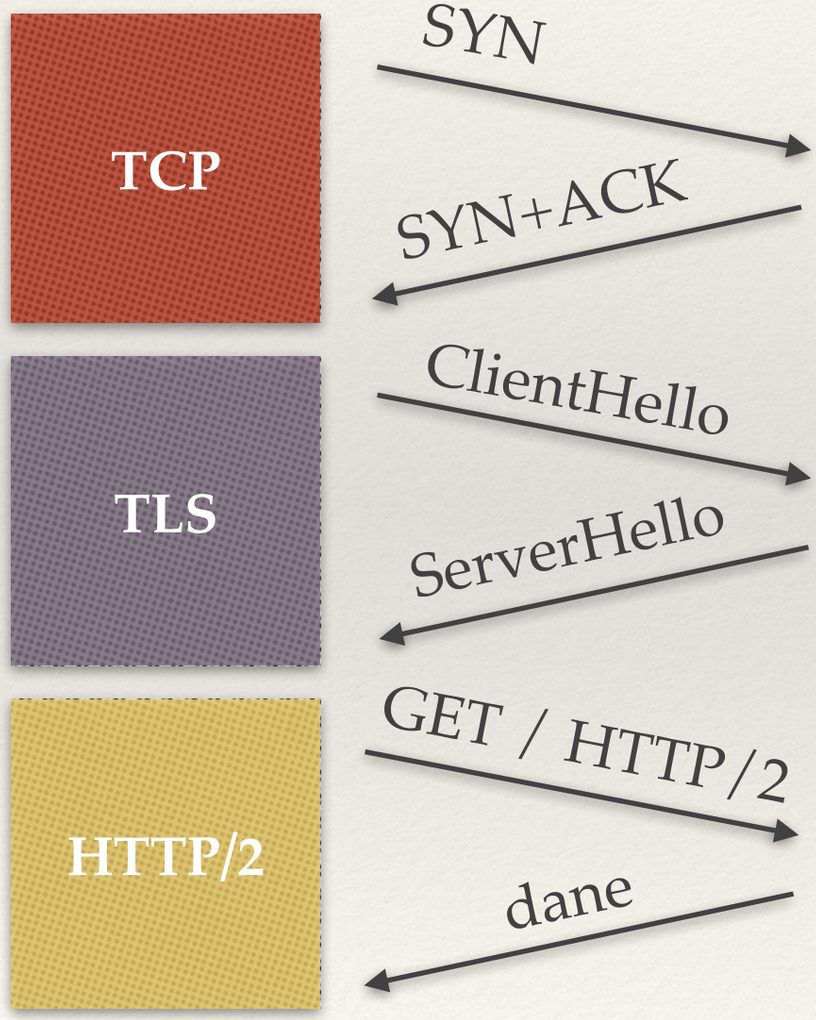

UDP + QUIC + HTTP/3

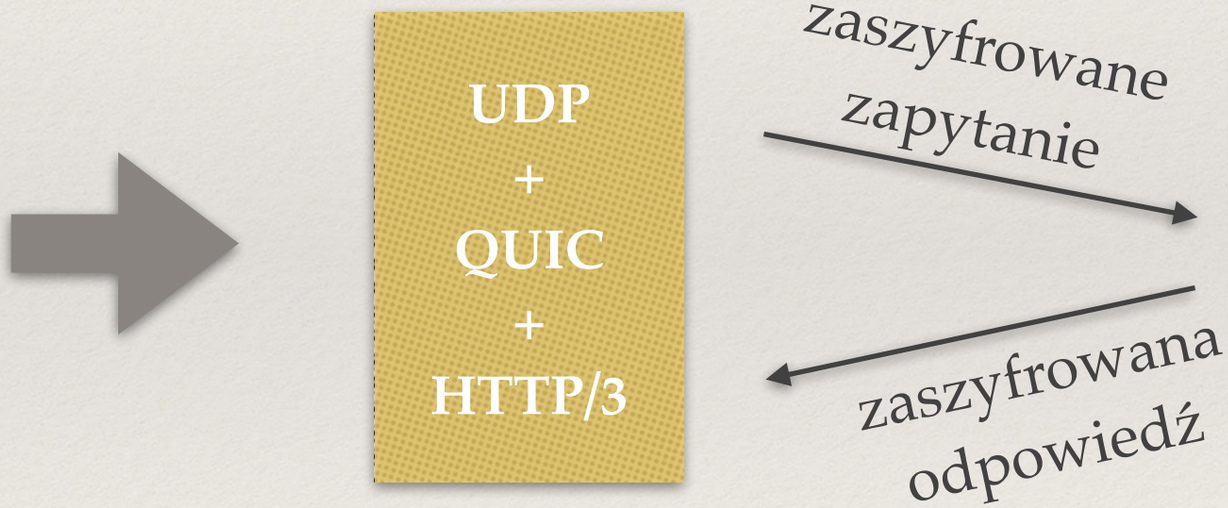

Wykorzystanie

Wykorzystanie jako procent całości ruchu HTTP (2025):

- HTTP/1.1: ~35%
- HTTP/2: ~50%
- HTTP/3: ~15%

Jak doszło do tak szybkiej adopcji nowych wersji?

Udział treści poszczególnych firm (2025)

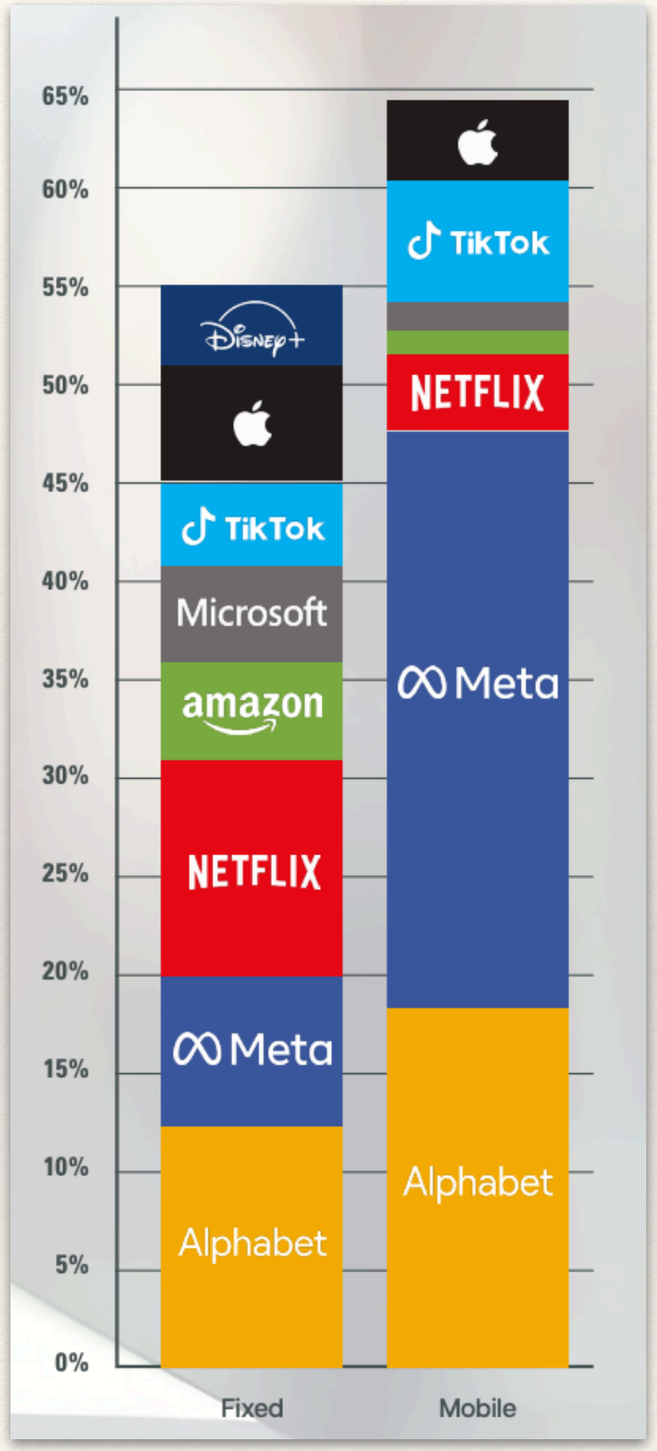

Obrazek z Global Internet Phenomena Report 2025
https://www.applogicnetworks.com/phenomena

Nowszych wersji HTTP używają:

- powyższe firmy
- sieci CDN

Lektura dodatkowa

- Kurose & Ross: rozdział 2.
- Tanenbaum: rozdział 7.

- Dokumentacja HTTP:
  - 1.1: `https://datatracker.ietf.org/doc/html/rfc2616`
  - 2: `https://datatracker.ietf.org/doc/html/rfc9113`
  - 3: `https://www.rfc-editor.org/rfc/rfc9114.html`
- QUIC Tutorial: `https://www.youtube.com/watch?v=31J8PoLW9iM`

- Raport Cloudflare za 2025: `https://radar.cloudflare.com/year-in-review/2025`

Zagadnienia

- Opisz budowę adresu URL. Opisz budowę adresu URL w przypadku schematu `http`.
- W jakim celu serwer WWW ustawia typ MIME dla wysyłanej zawartości? Podaj kilka przykładów typów MIME.
- Po co w nagłówku żądania `HTTP/1.1` podaje się pole `Host`?
- Do czego służą pola `Accept`, `Accept-Language`, `User-Agent`, `Referer`, `Server`, `Content-Length`, `Content-Type`, `Range` w nagłówku HTTP?
- Jak implementuje się przechowywanie stanu w komunikacji HTTP?
- Jak wygląda warunkowe zapytanie GET protokołu HTTP?
- Jakie znasz kody odpowiedzi protokołu HTTP?
- Na czym polegają połączenia trwałe w `HTTP/1.1`? Do czego służy opcja `Connection: close` w nagłówku HTTP?
- Po co stosuje się metodę POST?
- Co to jest technologia REST?
- Do czego służą serwery proxy?
- Co to jest odwrotne proxy? Co to jest CDN?
- Jak sprawić, żeby klient połączył się z serwerem proxy a nie bezpośrednio ze stroną WWW?
- Jakie informacje dołączane są przez serwer proxy do zapytania?
- Jakie usprawnienia wprowadza protokół HTTP/2?
- W jakim celu powstał protokół QUIC? Jakie funkcje spełnia?