SD 203
Développment Web
Internet et HTTP

Antoine Amarilli Pierre Senellart

2 décembre 2015

Vue générale

- Plusieurs échelles (locale et globale)
- Pile de protocoles
- Messages imbriqués

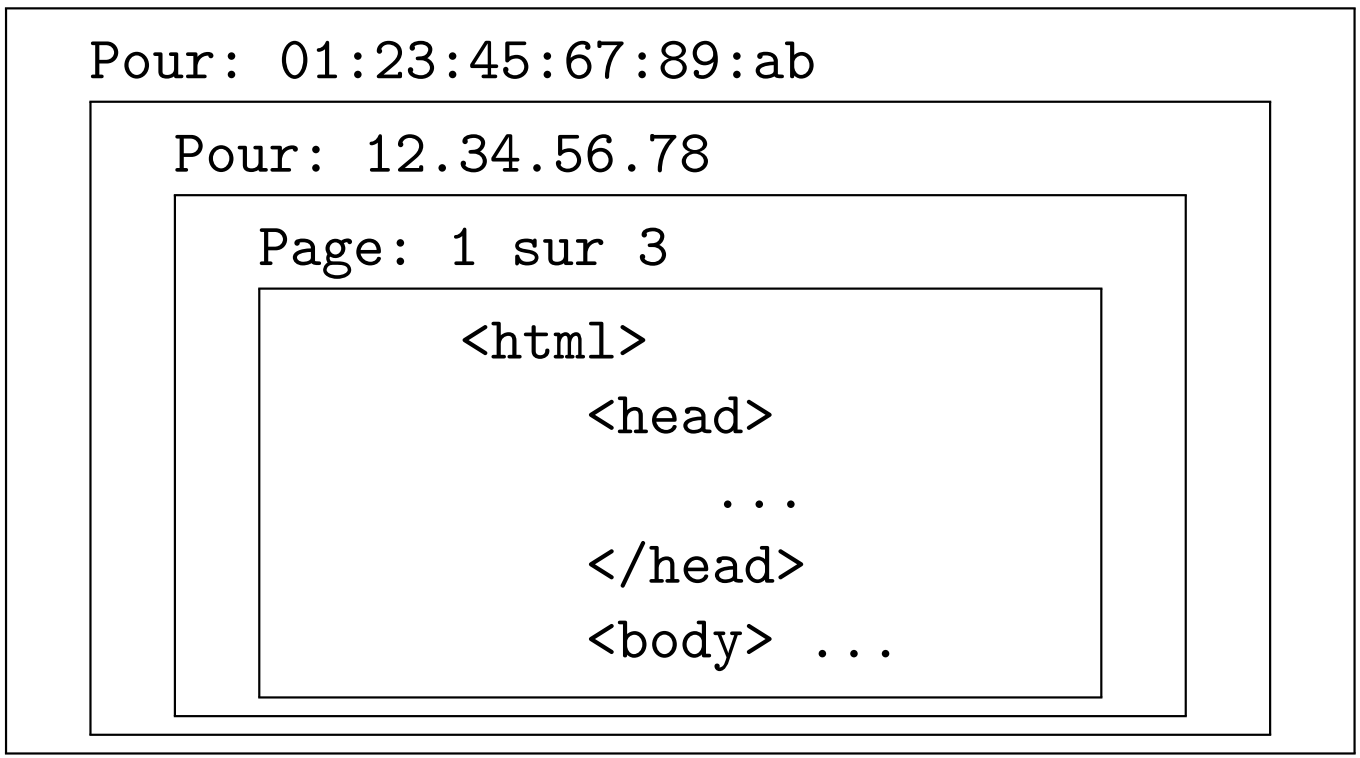

Le modèle OSI

#	Couche	Exemples	Fonctionnalités
7	Application	HTTP, FTP, SMTP	tâche utilisateur de haut niveau
4	Transport	TCP, UDP, ICMP	sessions, fiabilité, fragmentation
3	Réseau	IPv4, IPv6	routage, adressage, réseau non fiable
2	Lien	Ethernet, 802.11 (ARP)	données fiables, adresses locales
1	Physique	Ethernet, 802.11	échange physique, non fiable

→ Plus la couche est basse, plus l'enveloppe est à l'extérieur.

Table des matières

IP (Internet Protocol), couche 3

- Donner des adresses aux machines.
- Router des paquets entre ces adresses.
- Déterminer la position géographique d'une machine.

	Année	**Exemple**	**Adresses**	**Trafic**
IPv4	1981	$208.80.152.201$	$\leq 2^{32}$	99%
IPv6	1998	$2620:0:860:ed1a::1$	$\leq 2^{128}$	1% [1]

- Network Address Translation pour pallier la pénurie d'adresses.

→ On peut envoyer des messages à une adresse.

1. http://www.circleid.com/posts/20121128_ipv6_a_2012_report_card/, Nov. 2012

DNS (Domain Name System), intermède

- Adresses IP routables mais difficiles à mémoriser.
- Service pour convertir www.wikipedia.org en 208.80.152.201.
- Hiérarchie : `org`, `wikipedia.org`, `en.wikipedia.org`, etc.
- Résolution hiérachique.
- Cache à différents niveaux.
- Problèmes de sécurisation.
- Indirection :
  - Plusieurs adresses par nom de domaine (services multiples, répartition de charge).
  - Plusieurs noms de domaine par adresse (virtual hosts).

→ Qui gère le DNS ? Qui a droit à un nom de domaine ?

DNS (Domain Name System), intermède

- Adresses IP routables mais difficiles à mémoriser.
- Service pour convertir www.wikipedia.org en 208.80.152.201.
- Hiérarchie : `org`, `wikipedia.org`, `en.wikipedia.org`, etc.
- Résolution hiérachique.
- Cache à différents niveaux.
- Problèmes de sécurisation.
- Indirection :
  - Plusieurs adresses par nom de domaine (services multiples, répartition de charge).
  - Plusieurs noms de domaine par adresse (virtual hosts).

→ Qui gère le DNS ? Qui a droit à un nom de domaine ?

(Démo : résolution DNS avec `dig`.)

DNS (Domain Name System), intermède

- Adresses IP routables mais difficiles à mémoriser.
- Service pour convertir www.wikipedia.org en 208.80.152.201.
- Hiérarchie : `org`, `wikipedia.org`, `en.wikipedia.org`, etc.
- Résolution hiérachique.
- Cache à différents niveaux.
- Problèmes de sécurisation.
- Indirection :
  - Plusieurs adresses par nom de domaine (services multiples, répartition de charge).
  - Plusieurs noms de domaine par adresse (virtual hosts).

→ Qui gère le DNS ? Qui a droit à un nom de domaine ?

(Démo : résolution DNS avec `dig`.)

→ On peut envoyer des messages à une machine nommée.

TCP (Transmission Control Protocol), couche 4

- IP n'est pas fiable.
  → TCP fournit des accusés de réception.
- IP limite la taille.
  → TCP permet de fragmenter.
- IP n'est pas multiplexé.
  → TCP introduit des sessions et des ports. (e.g. 80 pour le Web... mais possible de forcer : `http://localhost:8080/`).

TCP (Transmission Control Protocol), couche 4

- IP n'est pas fiable.
  → TCP fournit des accusés de réception.
- IP limite la taille.
  → TCP permet de fragmenter.
- IP n'est pas multiplexé.
  → TCP introduit des sessions et des ports. (e.g. 80 pour le Web... mais possible de forcer : `http://localhost:8080/`).

(Démo : communication TCP avec `netcat`.)

TCP (Transmission Control Protocol), couche 4

- IP n'est pas fiable.
  → TCP fournit des accusés de réception.
- IP limite la taille.
  → TCP permet de fragmenter.
- IP n'est pas multiplexé.
  → TCP introduit des sessions et des ports. (e.g. 80 pour le Web... mais possible de forcer : `http://localhost:8080/`).

(Démo : communication TCP avec `netcat`.)

→ On peut avoir un canal de communication avec une machine.

Table des matières

TLS (Transport Layer Security), couche 5-6

- Messages échangés en clair ! Risques : confidentialité, e-commerce...
- Trois garanties : intégrité, authenticité, confidentialité.
- HTTP + TLS = HTTPS. URL en `https://`. Cadenas...
- Cryptographie asymétrique : deux machines sûres peuvent communiquer de façon sûre contre des attaquants passifs.
- Confidentialité persistente (perfect forward secrecy).
- Cryptographie symétrique pour des raisons de performance.
- Ne protège pas les métadonnées !
- Possibilité de fuites (taille, délai...).
- Impact légal sur la cryptographie.

TLS (Transport Layer Security), couche 5-6

- Messages échangés en clair ! Risques : confidentialité, e-commerce...
- Trois garanties : intégrité, authenticité, confidentialité.
- HTTP + TLS = HTTPS. URL en `https://`. Cadenas...
- Cryptographie asymétrique : deux machines sûres peuvent communiquer de façon sûre contre des attaquants passifs.
- Confidentialité persistente (perfect forward secrecy).
- Cryptographie symétrique pour des raisons de performance.
- Ne protège pas les métadonnées !
- Possibilité de fuites (taille, délai...).
- Impact légal sur la cryptographie.

(Démo : communication chiffrée avec `ncat --ssl`, tentatives d'interception infructueuses avec `tcpdump`.)

TLS et X.509

- Attaques actives, attaque de l'homme du milieu.

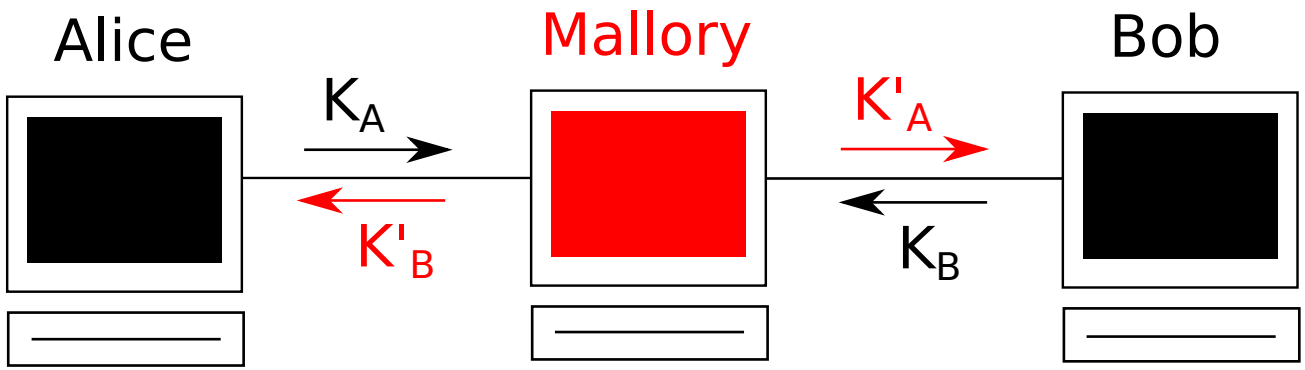

- Certificats (et messages d'erreur associés). Aussi utilisables pour l'authentification du client (mais peu utilisé).
- Qui sont les autorités de confiance ? (≥ 80 dans Chrome.)

TLS et X.509

- Attaques actives, attaque de l'homme du milieu.

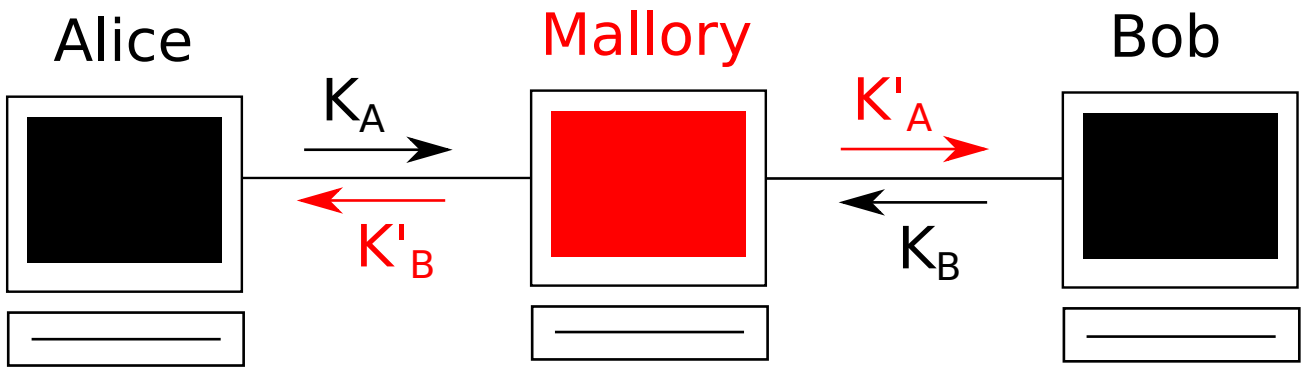

- Certificats (et messages d'erreur associés). Aussi utilisables pour l'authentification du client (mais peu utilisé).
- Qui sont les autorités de confiance ? (≥ 80 dans Chrome.)

$\rightarrow$ On peut avoir un canal de communication chiffré entre deux machines.

HTTP (HyperText Transfer Protocol), couche 7

- Le World Wide Web (WWW).
- Protocole de la navigation Web.

→ Pour résumer :

- Une machine client.
- Un logiciel client : le navigateur.
- Une machine serveur.
- Un logiciel serveur : le serveur Web.
- Un canal de communication fiable et chiffré.

Table des matières

Présentation générale

- Standardisé par l'Internet Engineering Task Force (IETF) et le World Wide Web Consortium (W3C).
- Protocole documenté : RFC 2616 (176 pages, 1999).
- Extensions : WebSockets, nouveaux headers...
- Mise à jour majeure : HTTP/2
  - À l'origine : SPDY, proposé par Google
  - Standardisé par la RFC 7540 (2015)
  - Meilleure efficacité (compression et multiplexing).
  - Supporté par 2% des sites Web aujourd'hui, majorité des navigateurs modernes.

La requête HTTP

- Du client vers le serveur, connexion TCP (+TLS).

```
GET /wiki/Telecom_ParisTech HTTP/1.1
Host: en.wikipedia.org
```

→ `http://en.wikipedia.org/wiki/Telecom_ParisTech`.

Méthode Plusieurs possibilités :
- **GET** La plus fréquente.
- **POST** Formulaires et effet de bord.
- **HEAD** Méta-infos seulement.
- **autres** PUT, DELETE...

Chemin C'est celui de l'URL.

Version Ici, 1.1 (essentiellement la seule).

Headers Infos supplémentaires (cf. plus tard).

Corps Passer des paramètres avec POST.

La requête HTTP

- Du client vers le serveur, connexion TCP (+TLS).

```
GET /wiki/Telecom_ParisTech HTTP/1.1
Host: en.wikipedia.org
```

→ `http://en.wikipedia.org/wiki/Telecom_ParisTech`.

Méthode Plusieurs possibilités :

- **GET** La plus fréquente.
- **POST** Formulaires et effet de bord.
- **HEAD** Méta-infos seulement.
- **autres** `PUT`, `DELETE`...

Chemin C'est celui de l'URL.

Version Ici, 1.1 (essentiellement la seule).

Headers Infos supplémentaires (cf. plus tard).

Corps Passer des paramètres avec `POST`.

(Démo avec `netcat`.)

La réponse HTTP

- Du serveur vers le client, dans la même connexion.

```
HTTP/1.1 200 OK
Content-Type: text/html; charset=UTF-8

<!DOCTYPE html>
<html>
  <head>
    (...)
```

- Code d'état et explication.
- Headers.
- Réponse (e.g., corps de la page).

Codes

- 1xx Information
- 2xx Succès
  - 200 : OK
- 3xx Redirection
  - 301 : permanente
  - 302 : temporaire
  - 304 : cf. le cache
- 4xx Erreur client
  - 400 : erreur de syntaxe
  - 401 : authentification nécessaire
  - 403 : interdit
  - 404 : non trouvé
- 5xx Erreur serveur
  - 500 : erreur interne du serveur

Chemins et paramètres

- Les chemins sont hiérachiques (séparateur : /).
- Conventions Unix : `http://en.wikipedia.org/./wiki/../`
- Ajout possible de paramètres non hiérarchique.
- Exemple : `https://www.google.com/search?q=telecom&ie=utf-8&oe=utf-8&client=iceweasel-a`
- Caractères spéciaux encodés : `https://fr.wikipedia.org/wiki/T%C3%A9l%C3%A9com_ParisTech`
- Utile pour les formulaires, autres encodages (cf. plus loin).

Table des matières

Header `Host`

- Plusieurs sites Web par machine :
  → `fr.wikipedia.org` et `en.wikipedia.org`.
- Le nom de domaine est perdu après la résolution DNS.
- Header pour repréciser le domaine attendu.

```
Host: en.wikipedia.org
```

Header `Host`

- Plusieurs sites Web par machine :
  → `fr.wikipedia.org` et `en.wikipedia.org`.
- Le nom de domaine est perdu après la résolution DNS.
- Header pour repréciser le domaine attendu.

  `Host: en.wikipedia.org`

(Démo : requête à `en.wikipedia.org` avec différents Hosts.)

Header User-Agent

- Identifier le navigateur utilisé.
- Est-ce un ordinateur ou un téléphone ?
- Est-ce un humain ou un robot ?
- Permet de contourner des bugs.
- Pas de garanties !
- Délires historiques (tout le monde dit "Mozilla/5.0").

```
User-Agent: Mozilla/5.0 (X11; Linux x86_64; rv:17.0)
  Gecko/20130810 Firefox/17.0 Iceweasel/17.0.8
```

Header `User-Agent`

- Identifier le navigateur utilisé.
- Est-ce un ordinateur ou un téléphone ?
- Est-ce un humain ou un robot ?
- Permet de contourner des bugs.
- Pas de garanties !
- Délires historiques (tout le monde dit "Mozilla/5.0").

```
User-Agent: Mozilla/5.0 (X11; Linux x86_64; rv:17.0)
  Gecko/20130810 Firefox/17.0 Iceweasel/17.0.8
```

(Démo : interception d'une requête de Firefox avec `mitmproxy`.)

Header Accept et Accept-*

- Plusieurs versions alternatives d'une ressource :

  Type de fichier. Différents formats de page Web...

  Langue. Anglais, français...

  Encodage. Compression à la volée.
- Négociation de contenu.
- Indique plusieurs choix et des priorités.
- En pratique, le type de fichier n'est pas vraiment utilisé.

```
Accept: text/html,application/xhtml+xml,
  application/xml;q=0.9,*/*;q=0.8
Accept-Language: en-US,en;q=0.5
Accept-Encoding: gzip, deflate
```

Header `Connection`

- HTTP 1.0 fermait la connexion après une requête.
- Inefficace, vu que TCP permet de gérer ça !
- Header `Connection` pour indiquer si la connexion doit/va rester ouverte ou non (client et serveur).
- Réutiliser la connexion après pour d'autres requêtes.
- HTTP 1.1 : la connexion reste ouverte par défaut.
- Timeout pour éviter de gaspiller des ressources.
- Pipelining : envoyer plusieurs requêtes et recevoir les réponses dans l'ordre.
  - → Avec HTTP 2.0, dans le désordre.

Header `Referer`

- Indique de quelle page le navigateur vient.
- Transmis après clic sur un lien ou soumission d'un formulaire.
- Pas de garanties !
- Quid de la vie privée ?

```
Referer: http://en.wikipedia.org/wiki/Telecom_ParisTech
```

Header Range

- Demander uniquement une certaine partie du fichier.
- Utile pour reprendre un téléchargement interrompu !
- Anecdote : en 2011, une faille pour planter le serveur Web le plus utilisé (Apache) en demandant une grande quantité de parties chevauchées. (CVE-2011-3192.)

```
Range: bytes=0-42
```

Table des matières

Header `Server`

- Identifie le serveur.
- (Toujours) pas de garanties !

Header `Server`

- Identifie le serveur.
- (Toujours) pas de garanties !

(Démo : réponse à la requête Firefox avec `mitmproxy`.)

Header Content-Type et Content-Length

- Plusieurs types de resources sur le Web : pages Web, mais aussi images, texte, PDF, multimédia...
  - → Nécessité d'identifier le type (quel document, quel format ?). Internet media type, historiquement Multipurpose Internet Mail Extensions (MIME).
- Plusieurs encodages (formats de représentation du texte) :
  - → Nécessité de préciser l'encodage pour certains documents.
- Afficher une barre de progression ?
  - → Préciser la longueur à l'avance.

```
Content-Type: text/html; charset=UTF-8
Content-Length: 4242
```

Encodages

Un encodage va numéroter les caractères et encoder les numéros.

ASCII. 128 caractères. Pas d'accents. 7 bits.

ISO-8859. 128 caractères en plus pour compléter ASCII.
1 octet. Français : ISO-8859-1 alias Latin-1.

Unicode. Numéroter tous les caractères ($> 100\,000$).

UTF-32. Représenter les caractères Unicode. 4 octets.

UTF-8. Un octet par caractère ASCII (et compatibilité),
davantage pour les non-ASCII. Longueur variable.

	Encodage ASCII		**Encodage Latin-1**		**Encodage UTF-8**	
	nb	repr.	nb	repr.	nb	repr.
A	65	01000001	65	01000001	65	01000001
é	-	-	233	11101001	233	11000011 10101001
ń	-	-	-	-	324	11000101 10000011

→ En pratique : utiliser UTF-8.

Table des matières

Authentification HTTP Basic

- Mécanisme simple de contrôle d'accès.
- Le serveur :
  - répond à une requête avec `401 Not Authorized`
  - identifie un domaine d'authentification avec le header `WWW-Authenticate: Basic realm="`*`foo`*`"`
- Le client :
  - encode réversiblement login et mot de passe : *digest*
  - renouvelle la requête avec le header : `Authorization: Basic` *digest*

→ Aucune sécurité si on n'utilise pas HTTPS !

Authentification HTTP Digest

- Le serveur envoie un nonce (message aléatoire) avec le domaine.
- Le client envoie un haché non réversible du nonce concaténé aux informations d'authentification.
- Le mot de passe ne circule pas en clair.
- Le haché utilisé est MD5 : est vieux et pas forcément sûr.
- `Basic` et `Digest` sont difficiles à distinguer pour l'utilisateur.

→ Authentification HTTP peu utilisée car peu flexible.

Proxies

- Proxy (serveur mandataire) : effectue (ou relaie) des requêtes Web pour le compte d'autrui.
- Peut s'utiliser côté client ou côté serveur.
- Nombreuses utilisations :
  - Filtrer ou censurer le Web (employeurs, écoles, régimes totalitaires, contrôle parental, etc.).
  - Conserver un journal de l'activité.
  - Conserver un cache (cache commun à plusieurs utilisateurs).
  - Anonymisation (cacher la véritable origine de la requête).
  - Autres modifications : traduction, etc.
- Avec SSL, c'est plus difficile !

Cache

- Sauvegarder le résultat d'une requête pour la réutiliser.
- Plusieurs caches possibles : proxies, ou le navigateur.
- Serveur :

  `Cache-Control` Indiquer si on peut conserver en cache : `public`, `private`, `no-cache`/`no-store`.

  `Expires` Date d'expiration.

  `ETag` Identifiant de version.

- Client :

  `Pragma: no-cache` Interdire aux proxies d'utiliser leur cache.

  `If-Modified-Since` Si modifié depuis une certaine date.

  `If-None-Match` Si l'identifiant de version a changé.

Cookies

- Pas de sessions en HTTP.
- Le serveur peut demander au client de mémoriser une valeur :
  `Set-Cookie: nom=valeur; option1; option2` :

`expires`	date d'expiration (peut être lointaine)
`domain`	limite la portée (domaine, sous-domaine)
`path`	limite la portée (sous-chemin)
`secure`	seulement sur SSL
`httpOnly`	pas lisible par JavaScript

- Le client fournit la valeur avec chaque requête :
  `Cookie: nom=valeur`
- Le client peut lire et modifier des cookies (pas de garanties) et les effacer (vie privée)

Utilisation des cookies

- Stocker un identifiant de session opaque. (Interception ?)
- Garder l'utilisateur connecté sur de longues périodes.
- Traquer un utilisateur de façon unique (même sans compte).
- Risques :

  Sécurité Il ne faut pas qu'un cookie soit divulgué au mauvais site !

  Vie privée (Mais le cache est exactement équivalent !)