Unix et Programmation Web

Cours 4

kn@lri.fr
http://www.lri.fr/~kn

Plan

Bref historique d'Internet (1/2)

1959-1968 : ARPA (*Advanced Research Project Agency*) crée un réseau de quelques machines capable de résister à une attaque.

1969 : ARPANET. Interconnexion des ordinateurs centraux des grandes universités et institutions américaines. Première utilisation du concept de paquet d'information.

1970-1982 : Interconnexion avec la Norvège et le Royaume-Uni.

1982 : Passage au protocole TCP/IP. Naissance de l'Internet actuel.

Bref historique d'Internet (2/2)

1986 : « Autoroutes de l'information ». Des super-ordinateurs et les premières connexions à fibres optiques sont utilisées pour accélérer le débit d'Internet.

1987-1992 : Apparition des premiers fournisseurs d'accès. Les entreprises se connectent.

1993-2000 : Avènement du Web. Démocratisation du haut-débit (vers 2000 pour la France).

2000-présent : Explosion des services en ligne, arrivée des réseaux sociaux, internet mobile, *Cloud* (stockage et calcul mutualisés accessible depuis internet).

Internet

- Ensemble de logiciels et protocoles basés sur TCP/IP
- Modèle Client/Serveur
- Un serveur fournit un service:
  - courriel
  - transfert de fichier (ftp)
  - connexion à distance (ssh)
  - Web (http)
- Plusieurs services peuvent être actifs sur la même machine (serveur). Un port (identifiant numérique) est associé à chaque service. Sur Internet, un service est identifié par:
  - L'adresse IP de la machine sur lequel il fonctionne
  - Le numéro de port sur lequel le programme attend les connexions

Exemples de services

Service	Protocole	Port	Description
ftp	File Transfer Protocol	20,21	Transfert de fichiers
telnet	Network Virtual Terminal	23	Shell à distance
ssh	Secure Shell	22	Shell à distance crypté
mail	Simple Mail Transfer Protocol	25	Envoi de mail
pop	Post Office Protocol	110	Récupération de mail
imap	Internet Message Access Protocol	143	Synchronisation de mails
nslookup	Domain Name System	42	Serveur de noms
http	Hyper Text Transfer Protocole	80	Web

World Wide Web (1/2)

- Service de distribution de page hypertexte
- Une page hypertexte contient des références immédiatement accessibles à d'autres pages (pointeurs ou liens hypertextes)
- Les pages sont décrites dans le langage HTML (HyperText Markup Language)
- Architecture client/serveur:
  - Les pages sont stockées sur le serveur
  - Les pages sont envoyées au client (navigateur Web) qui en assure le rendu
- Utilise le protocole HTTP pour les échanges entre le client et le serveur

World Wide Web (2/2)

Concepts clé:

URL : localisation d'une page Web (« adresse de la page »)
HTTP : protocole de communication entre un client et un serveur Web
HTML : langage de description des pages Web

Évolutions récentes (Web 2.0, internet mobile, *Cloud*, ...)

- Standardisation du contenu multimédia (images, vidéos et sons en *streaming*)
- Contenu interactif avancé (stockage de fichier coté client, rendu 3D, ...)
- Uniformisation de nombreuses extensions *ad-hoc*: HTML5

Plan

Fonctionnement du Web

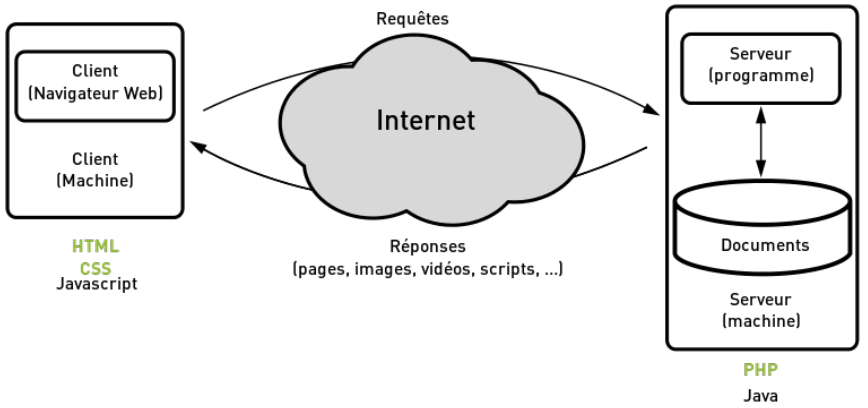

Côté client

Le navigateur :

- Analyse l'URL demandée
- Obtient l'adresse IP auprès du serveur DNS
- Établit une connexion (potentiellement sécurisée) avec le serveur
- Envoie une requête HTTP au serveur
- Récupère la page envoyée par le serveur dans sa réponse
- Analyse la page et récupère les éléments référencés : images, sons, ...
- Effectue le traitement du code client
- Met en forme le contenu et l'affiche dans la fenêtre

Côté serveur

- Un *listener* (*thread* particulier) attend les connexions sur un port par défaut (80 dans le cas de HTTP)
- À chaque nouvelle connexion, le *listener* crée un *thread* de traitement et se remet en attente
- Le *thread* de traitement vérifie la validité de la requête :
  - le document demandé existe ?
  - le client est autorisé à accéder au document ?
  - ...
- Le *thread* de traitement répond à la requête :
  - Exécution de code côté serveur, récupération de données dans une BD, ...
  - Envoi de la page au client

Plan

Adressage des documents Web (1/3)

URL : ***Uniform Resource Locator*** **identifie un document sur internet**

Une URL se décompose en 3 partie

- **protocole (comment ?)**
- **adresse (où ?)**
- **document (quoi ?)**

Syntaxe (simplifiée) :

```
protocole://adresse/document
```

Exemple :

```
http://www.lri.fr/~kn/teach_fr.html
```


Adressage des documents Web (2/3)

On peut aussi préciser un numéro de port, des paramètres et un emplacement :

```
protocole://adresse:port/document?p1=v1&p2=v2#empl
```

Exemple :

```
http://www.youtube.com:80/results?search_query=tbbt#search-results
```

Le serveur utilise les paramètres passés par le client dans l'URL pour *calculer* le contenu de la page (changer la chaîne « `tbbt` **» ci-dessus et essayer)**

Adressage des documents Web (3/3)

La racine d'un site Web (ex: `http://www.lri.fr/` **) correspond à un répertoire sur le disque du serveur (ex:** `/var/www` **). Le fichier**

```
http://www.lri.fr/index.html
```

se trouve à l'emplacement

```
/var/www/index.html
```

Le serveur Web peut aussi effectuer des réécritures d'adresses :

```
http://www.lri.fr/~kn/index.html
```

devient

```
/home/kn/public_html/index.html
```

Plan

1 Réseaux, TCP/IP ✔
2 Web et HTML
- 2.1 Internet et ses services ✔
- 2.2 Fonctionnement du Web ✔
- 2.3 Adressage des documents Web ✔
- 2.4 Le protocole HTTP
- 2.5 HTML, le format des documents
- 2.6 Encodage des caractères (UTF-8) (digression)

Caractéristiques du protocole HTTP

- Sans connexion permanente:
  - Le client se connecte au serveur, envoie sa requête, se déconnecte
  - Le serveur se connecte au client, envoie sa réponse, se déconnecte
- Indépendant du contenu : permet d'envoyer des documents (hyper) texte, du son, des images, ...
- Sans état: chaque paire requête/réponse est indépendante (le serveur ne maintient pas d'information sur le client entre les requêtes)
- Protocole en mode texte

Format des messages HTTP

Les messages ont la forme suivante

- Ligne initiale CR LF
- zéro ou plusieurs lignes d'option CR LF
- CR LF
- Corp du message (document envoyé, paramètres de la requête, ...)

- Requête la première ligne contient un nom de méthode (GET, POST, HEAD, ...), le paramètre de la méthode et la version du protocole
- Réponse la version du protocole, le code de la réponse (200, 404, 403, ...) et un message informatif

Démo

Plan

1 Réseaux, TCP/IP ✔
2 Web et HTML
- 2.1 Internet et ses services ✔
- 2.2 Fonctionnement du Web ✔
- 2.3 Adressage des documents Web ✔
- 2.4 Le protocole HTTP ✔
- 2.5 HTML, le format des documents
- 2.6 Encodage des caractères (UTF-8) (digression)

HTML

HyperText Markup Language : langage de mise en forme de documents hypertextes (texte + liens vers d'autres documents). Développé au CERN en 1989.
1991 : premier navigateur en mode texte
1993 : premier navigateur graphique (mosaic) développé au NCSA (National Center for Supercomputing Applications)

Document HTML

- est un document semi-structuré
- dont la structure est donnée par des balises

Exemple	Rendu par défaut
`Un texte <b>en gras</b>`	Un texte **en gras**
`<a href="http://www.u-psud.fr">Un lien</a>`	Un lien
`<ul >   <li>Premièrement</li>   <li>Deuxièmement</li> </ul>`	▪ Premièrement ▪ Deuxièmement

On dit que `<toto>` est une balise ouvrante et `</toto>` une balise fermante. On peut écrire `<toto/>` comme raccourci pour `<toto></toto>`.

Historique du langage HTML

1973 : GML, Generalised Markup Language développé chez IBM. Introduction de la notion de balise.
1980 : SGML, Standardised GML, adopté par l'ISO
1989 : HTML, basé sur SGML. Plusieurs entreprises (microsoft, netscape, ...) interprètent le standard de manière différente
1996 : XML, eXtensible Markup Language norme pour les documents semi-structurés (SGML simplifié)
2000 : XHTML, version de HTML suivant les conventions XML
2008 : Première proposition pour le nouveau standard, HTML5
2014 : Standardisation de HTML5

XHTML *vs* HTML

On utilise XHTML dans le cours. Différences avec HTML:

- Les balises sont bien parenthésées (<a> <c> </c> est interdit)
- Les balises sont en minuscules

Les avantages sont les suivants

- HTML autorise les mélanges majuscule/minuscule, de ne pas fermer certaines balise ... Les navigateurs corrigent ces erreurs de manières différentes
- Le document est structuré comme un programme informatique (les balises ouvrantes/fermantes correspondent à { et }). Plus simple à débugger.

Rôle d'(X)HTML

Séparer la structure du document de son rendu. La structure donne une sémantique au document :

- ceci est un titre
- ceci est un paragraphe
- ceci est un ensemble de caractères importants

Cela permet au navigateur d'assurer un rendu en fonction de la sémantique. Il existe différents types de rendus:

- graphique interactif (Chrome, Firefox, Internet Explorer, ...)
- texte interactif (Lynx, navigateur en mode texte)
- graphique statique (par ex: sur livre électronique)
- rendu sur papier
- graphique pour petit écran (terminal mobile)

Exemple de document

(liste des balises données sur la feuille de TD 4!)

```
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
  "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
<html xmlns="http://www.w3.org/1999/xhtml" xml:lang="fr" >
  <head>
    <title>Un titre</title>
    <meta http-equiv="Content-Type" content="text/html;charset=utf-8" />
  </head>
  <body>
    <h1>Titre de section</h1>
    <p> premier paragraphe de texte. On met
    un <a href="http://www.lri.fr">lien</a> ici.
    </p>
    <!-- on peut aussi mettre des commentaires -->
  </body>
</html>
```


Structure d'un document XHTML

Pour être *valide* un document XHTML contient au moins les balises suivantes :

- Une balise `html` qui est la racine (elle englobe toutes les autres balises). La balise `html` contient deux balises filles: `head` et `body`
- La balise `head` représente l'en-tête du document. Elle peut contenir diverses informations (feuilles de styles, titre, encodage de caractères, ...). La seule balise obligatoire dans `head` est le titre (`title`). C'est le texte qui est affiché dans la barre de fenêtre du navigateur ou dans l'onglet.
- la balise `body` représente le contenu de la page. On y trouve diverses balises (`div`, `p`, `table`, ...) qui formattent le contenu de la page

Plan

1 Réseaux, TCP/IP ✔
2 Web et HTML
- 2.1 Internet et ses services ✔
- 2.2 Fonctionnement du Web ✔
- 2.3 Adressage des documents Web ✔
- 2.4 Le protocole HTTP ✔
- 2.5 HTML, le format des documents ✔
- 2.6 Encodage des caractères (UTF-8) (digression)

Représentation des textes

Avant de représenter des documents complexes, on s'intéresse aux textes (sans structure particulière)

Problématique: comment représenter du texte réaliste ?

Exemple de texte réaliste:
" و عليكم السلام,Здравей,¡Hola!, 你好,Góðan daginn,... "

Historiquement...

Encodage 1 caractère = 1 octet (8 bits) :

- Encodage ASCII sur 7 bits (128 caractères)
- ASCII étendu 8 bits (256 caractères, dont 128 de « symboles »
- Latin 1 : ASCII 7 bits + 128 caractères « ouest-européens » (lettres accentuées française, italienne, ...)
- Latin 2 : ASCII 7 bits + 128 caractères « est-européens » (Serbe, Hongrois, Croate, Tchèque, ...)
- Latin 3 : ASCII 7 bits + 128 caractères turques, maltais, esperanto,
- Latin 4 : ASCII 7 bits + 128 caractères islandais, lituanien, ...
- ...
- Latin 15 : Latin 1 avec 4 caractères « inutiles » remplacés (par exemple pour « € » à la place de « ¤ »)

... et pendant ce temps là, ailleur dans le monde

Encodage multi-octets:

- Encodages spécifiques pour le Chinois (Big5, GB, ...)
- Encodages spécifiques pour le Japonais (Shift-JIS, EUC, ...)

Impossibilité de mettre plusieurs « alphabets » dans un même texte

Chaque logiciel « interprétait » les séquences d'octet de manière prédéfinie

UTF-8

Universal (Character Set) Transformation Format 8 bit

- Encodage à taille variable « universel » (contient tous les alphabets connus)
- Un organisme (ISO) donne un code à chaque symbole
- Compatible avec ASCII 7 bits

Encodage

Nombre d'octets	Octet 1	Octet 2	Octet 3	Octet 4	Octet 5	Octet 6
1	0xxxxxxx					
2	110xxxxx	10xxxxxx				
3	1110xxxx	10xxxxxx	10xxxxxx			
4	11110xxx	10xxxxxx	10xxxxxx	10xxxxxx		
5	111110xx	10xxxxxx	10xxxxxx	10xxxxxx	10xxxxxx	
6	1111110x	10xxxxxx	10xxxxxx	10xxxxxx	10xxxxxx	10xxxxxx

Exemples

A ⟶ 65_{10} ⟶ $0100\ 1010_2$ (représenté sur un seul octet)

ế ⟶ 7877_{10} ⟶ $0001\ 1110\ 1100\ 0101_2$ (représenté 3 octets) :
1110 0001 1011 10 11 1000 0101 ≡ 225 187 133

 ⟶ 128053_{10} ⟶ ... ≡ 240 237 220 181

Avantages

- compatible ASCII 7 bits (d'anciens documents texte en anglais sont toujours lisibles)
- pas d'espace gaspillé (à l'inverse d'UTF-32 ou tous les caractères font 32 bits)

Inconvénients

- Caractères à taille variable: il faut parcourir le texte pour trouver le $n^{ème}$ caractère
- Les vieux logiciels doivent être adaptés