INF344 – Données du Web
Technologies côté serveur

Antoine Amarilli

9 mai 2018

Serveurs

Traiter la requête (cas simples) ou la rediriger à un autre programme (cas complexes)

Apache	Logiciel libre et gratuit, lancé en 1995
IIS	Fourni avec Windows, propriétaire
nginx	Haute performance, libre et gratuit, lancé en 2002 (Août 2013, lancement de Nginx Plus, payant)
GWS	Google Web Server, interne (trafic de Google !)
lighttpd	Alternative légère à Apache
Autres	Rares, expérimentaux, embarqués...

Parts de marché

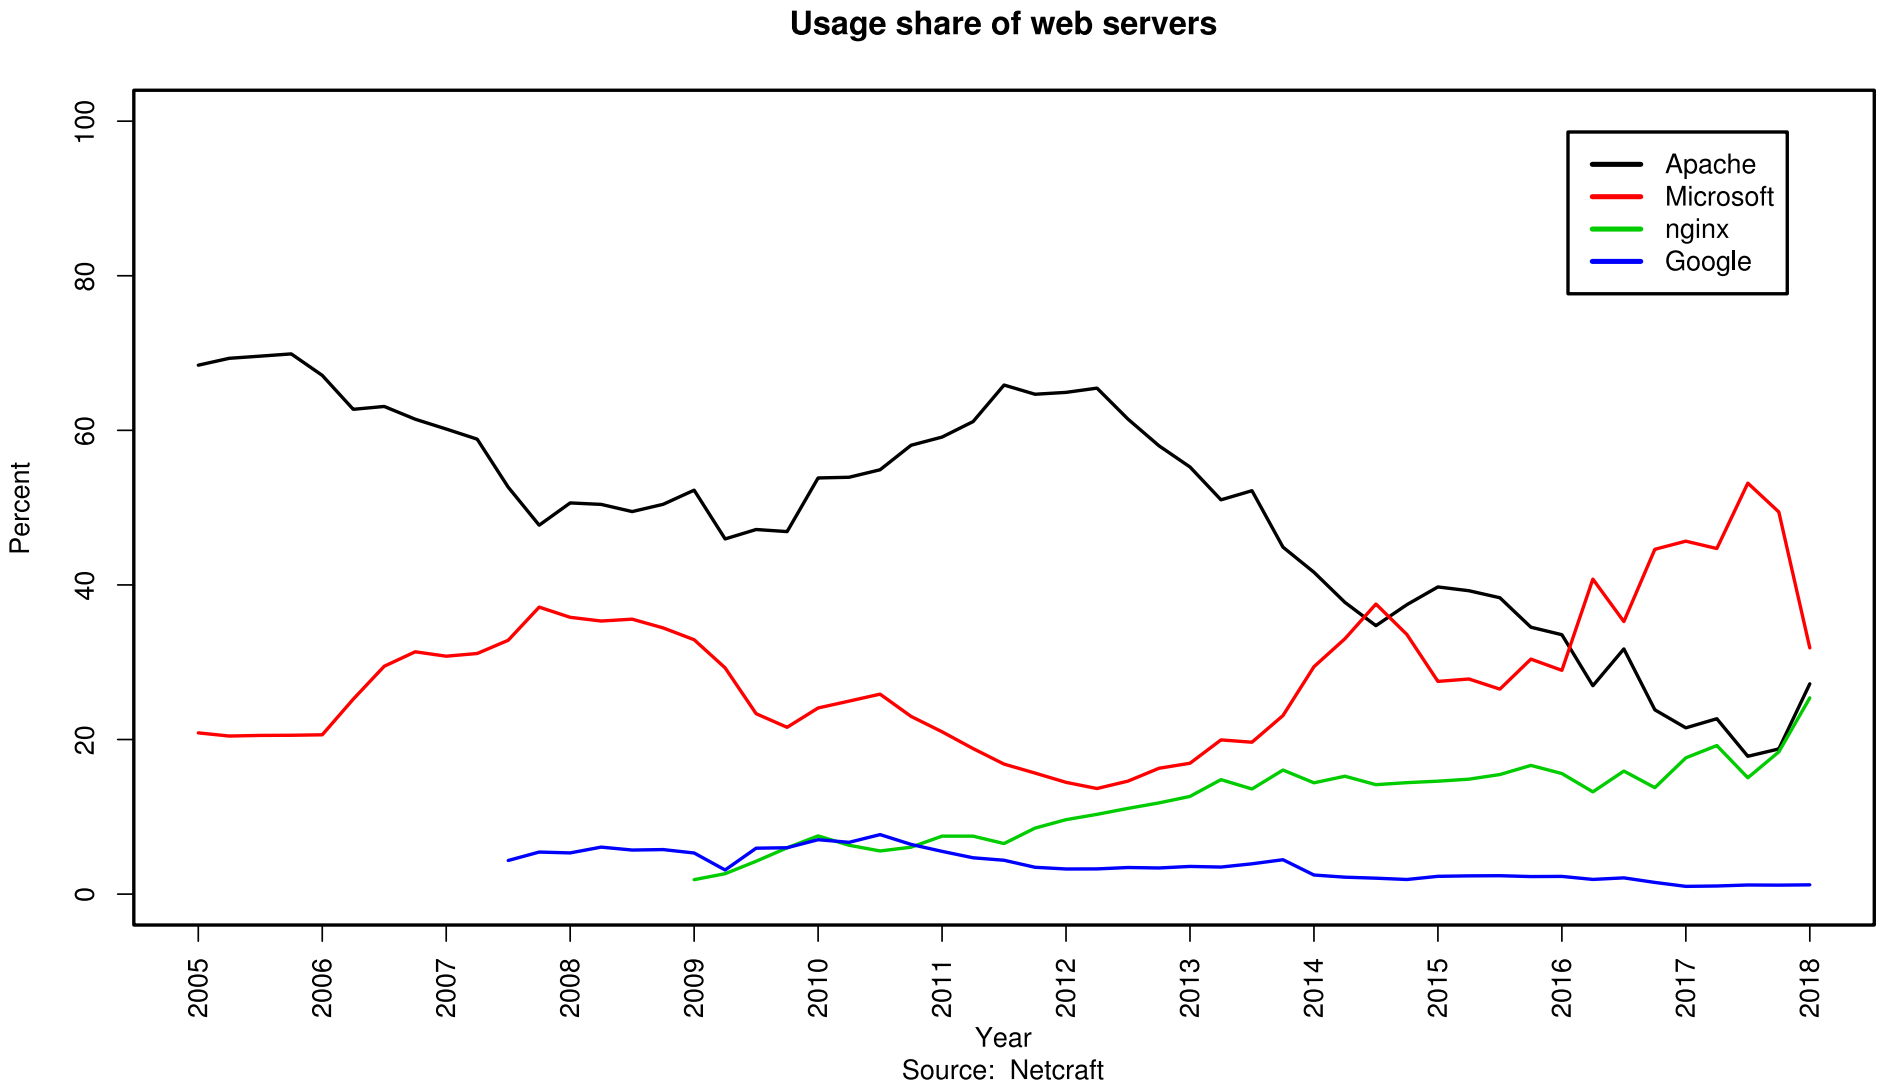

Sites Web statiques simples

- Les différentes ressources sont stockées dans des **fichiers** :
  → `/var/www/page.html`, `/var/www/style.css`…
- Les pages sont organisées en une **arborescence** de répertoires
- Les chemins demandés **correspondent** à l'arborescence :
  → `GET /a/b.html` correspond à `/var/www/a/b.html`
- Si un **répertoire** est demandé :
  - Servir `index.html` s'il existe
  - Sinon, produire une liste des fichiers du répertoire

→ **Pérennité** des URLs ?

Sites Web statiques simples

- Les différentes ressources sont stockées dans des **fichiers** :
  → `/var/www/page.html`, `/var/www/style.css`…
- Les pages sont organisées en une **arborescence** de répertoires
- Les chemins demandés **correspondent** à l'arborescence :
  → `GET /a/b.html` correspond à `/var/www/a/b.html`
- Si un **répertoire** est demandé :
  - Servir `index.html` s'il existe
  - Sinon, produire une liste des fichiers du répertoire

→ **Pérennité** des URLs ?

(Démo : naviguer dans une arborescence)

Extensions Apache

- Les fichiers `.htaccess` permettent de paramétrer Apache :
  - `deny from all` pour interdire un répertoire
  - Authentification HTTP
- URL rewriting :
  - `RewriteRule (.*\.png) /images/$1`
- Server Side Includes :
  - `<!-#include virtual="/footer.html" ->`

Table des matières

CGI

- Moyen historique pour un **serveur Web** d'invoquer un **programme externe** (n'importe quel langage)
- Exécute le **programme** sur les paramètres de la requête
- Le résultat de la requête est ce que **renvoie** le programme
- **Inconvénient** : créer un processus par requête est trop lourd
  - → **FastCGI** et autres mécanismes
  - → **Intégrer** le langage au serveur (par exemple PHP)

PHP

- Lancé en 1995 ; des **centaines de millions** de sites l'utilisent [1]
- Langage de programmation **complet**
- S'ajoute aux pages HTML. Exemple :

```
<ul>
<?php
  $from = intval($_POST['from']);
  $to = intval($_POST['to']);
  for ($i = $from; $i < $to; $i++) {
    echo "<li>$i</li>";
  }
?>
</ul>
```

1. https://secure.php.net/usage.php

Inconvénients de PHP

- Pas prévu comme un langage complet à l'origine
  - → À l'origine, Personal Home Page
  - → Difficile d'assurer la compatibilité…
- Encourage de mauvaises pratiques de sécurité
  - → Historiquement, `$_POST['from']` accessible comme `$from`!
  - → Facile d'oublier de (re)valider les données utilisateur…
- Mauvaises performances ?
  - → À l'origine, langage interprété
  - → Machine virtuelle avec compilation JIT (HHVM à Facebook)

Autres langages côté serveur

ASP Microsoft, add-on à IIS, propriétaire

ASP.NET Microsoft, successeur d'ASP pour .NET

ColdFusion Adobe, commercial, propriétaire

JSP Intégration entre Java et un serveur Web

- **Servlet** classe Java suivant une API
- **Web container** serveur pour gérer les servlets (par exemple Apache Tomcat)

node.js Moteur JavaScript V8 (de Chrome) et serveur Web

→ Même langage pour le client et le serveur

Python Frameworks Web : Django, CherryPy, Flask

Ruby Frameworks Web : Ruby on Rails, Sinatra

Table des matières

Bases de données

- SGBD : Système de Gestion de Bases de Données
- Abstraction de la tâche de stocker de l'information, la mettre à jour, et la récupérer suivant des requêtes
- Modèle historique et le plus courant : modèle relationnel, SQL
- Avantages :
  - Gérer simplement les données sans s'occuper du stockage
  - Remplacer plutôt facilement un SGBD par un autre
  - Facilement déléguer la tâche à des machines séparées
  - Optimiser les SGBD plutôt que les usages ad hoc
- Déviations du modèle relationnel : NoSQL

Modèle relationnel : structure

- Relations (tables), par exemple `Clients`, `Produits`…
- Attributs (colonnes), par exemple `Prénom`, `Identifiant`…
- Enregistrements (lignes)
- Exemple : table `clients` :

`id`	`prenom`	`nom`	`cp`	`ville`	`conseiller`
1	Jean	Dupont	75013	Paris	42
2	François	Pignon	75005	Paris	42

- Les attributs ont un type (chaîne de caractères, nombre entier, décimal, date, blob binaire…)

SQL

- Structured Query Language
- Sémantique et modèle propre, liens avec la logique
- Standardisé (1986, mis à jour en 2011) mais extensions...
- Sélection :

```
SELECT ville, COUNT(*)
FROM clients
WHERE conseiller=42
GROUP BY ville;
```

- Mise à jour :

```
UPDATE clients
SET conseiller=43
WHERE conseiller=42 AND cp=75013;
```

SGBDs

Oracle	Commercial et propriétaire, lancé en 1979
IBM DB2	IBM, commercial et propriétaire, Lancé en 1983
Informix	Autre système IBM, lancé en 1981 (rachat)
SQL Server	Microsoft, commercial et propriétaire, lancé en 1989
MySQL	Libre (mais éditions commerciales), le plus courant sur le Web, lancé en 1995, racheté par Oracle
MariaDB	Fork de MySQL, lancé en 2009
PostgreSQL	Libre, concurrent de MySQL, lancé en 1995
SQLite	Librairie dans un programme, léger, lancé en 2000

SGBDs, parts de marché en entreprise (cumulatives)

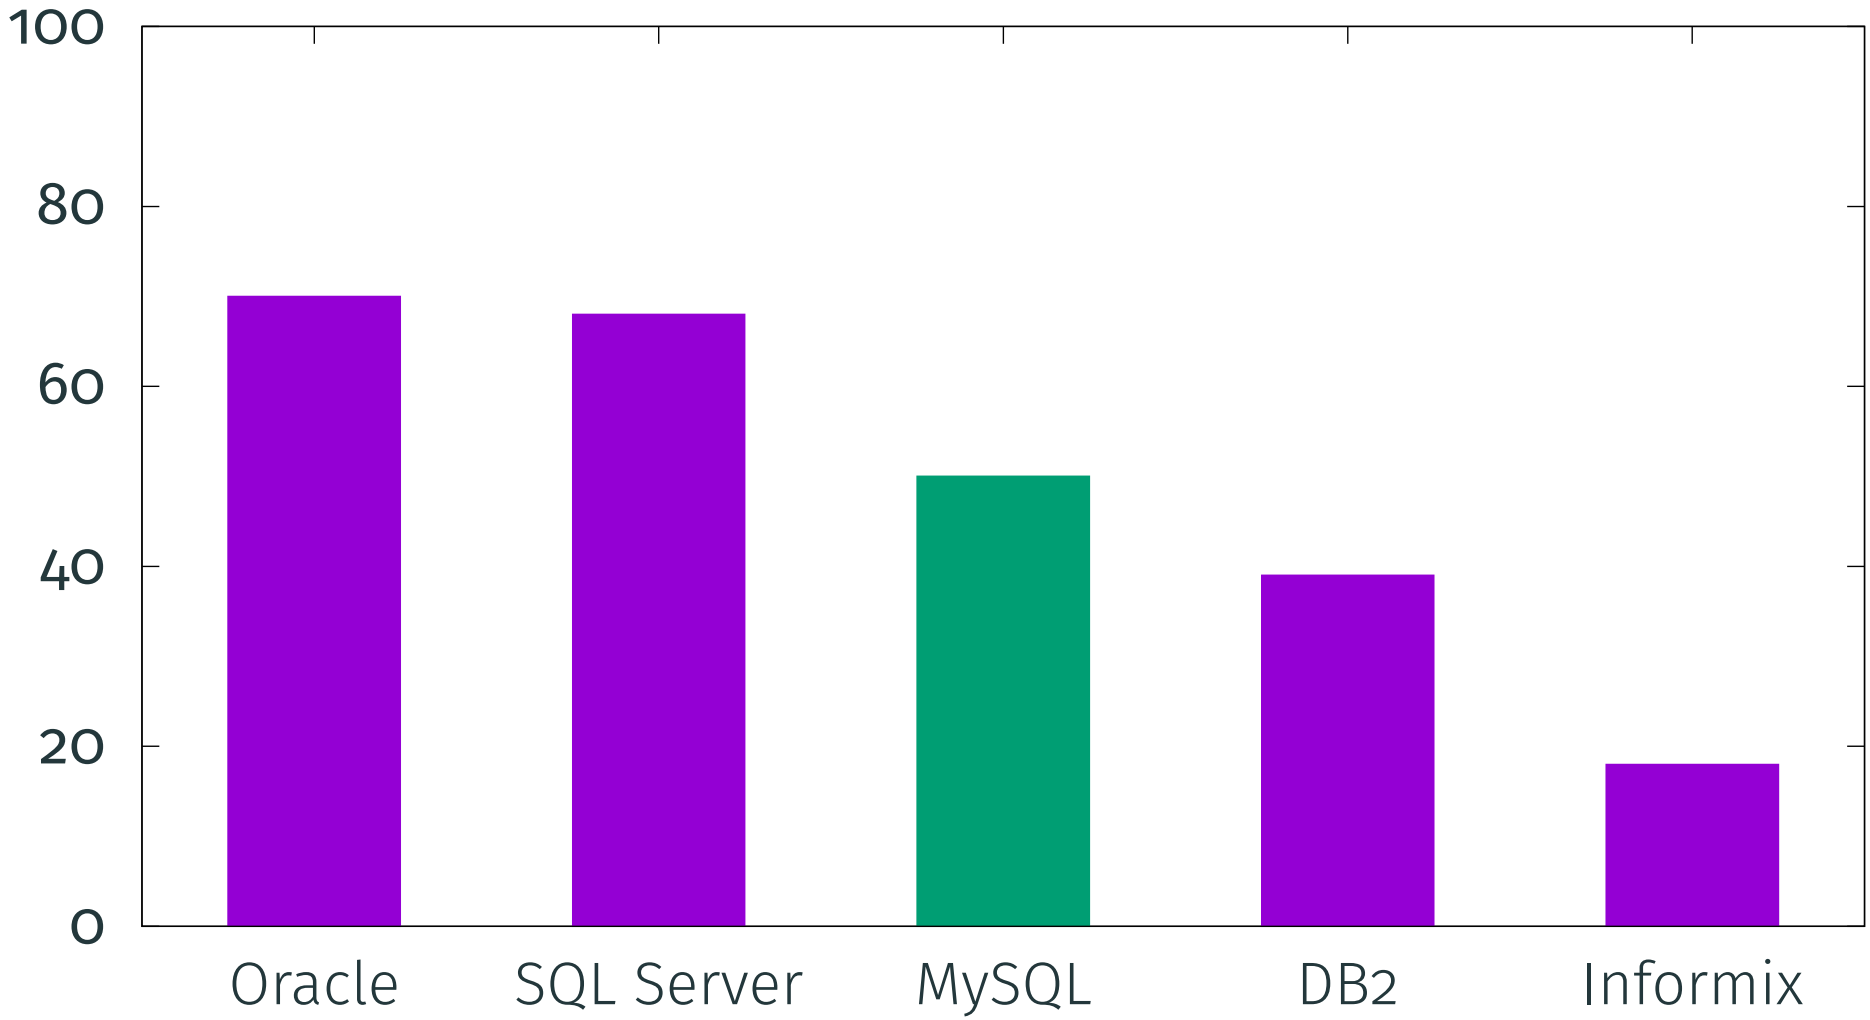

Source : étude Gartner de 2008 citée dans

`https://www.mysql.com/why-mysql/marketshare/`

Modèle relationnel : idées importantes

- Contraintes d'intégrité :
  - Clés primaires : identifiant unique, détermine l'enregistrement
  - Clés étrangères : valeur qui fait référence à une clé primaire
- Formes normales : éviter la répétition des données
- Procédures stockées : code pour des requêtes complexes
- Vues : table virtuelle définie par une requête (matérialisée ?)
- Triggers : répondre à un événement
- Transactions : atomicité pour éviter les incohérences
- Distribution : répartir entre plusieurs machines
- Concurrence : traiter des requêtes simultanées
- Performance : index, caches mémoire, etc.
- Utilisateurs et droits d'accès (toujours relégué à PHP ou au framework Web en pratique)

NoSQL

- Beaucoup d'**expressivité** avec le modèle relationnel
- Structure très **contrainte** et peu modifiable
- Exigences fortes de **cohérence** sur du relationnel distribué

→ **NoSQL** : renoncer au modèle relationnel pour de meilleures performances et un meilleur passage à l'échelle

- Quelques exemples :
  - Stockage de **documents** entiers peu structurés
  - Stockage de **graphes**
  - Stockage de couples **clé-valeur**
  - Stockage de **triplets** pour le Web sémantique
- Système le plus populaire[2] : **MongoDB**, utilisé par Craigslist, le CERN, Shutterfly, Foursquare, etc.

2. `https://db-engines.com/en/ranking`

Injections SQL

- Une application serveur fabrique souvent des requêtes à partir de **données utilisateur** :

```
SELECT nom, telephone FROM employes WHERE nom='$nom'
```

- Si l'utilisateur soumet `toto`, on veut exécuter la requête :

```
SELECT nom, telephone FROM employes WHERE nom='toto'
```

- Maintenant, imaginons qu'un utilisateur soumette :

```
toto' UNION ALL SELECT nom, mdp FROM employes --
```

- La base de données va recevoir et exécuter :

```
SELECT nom, telephone FROM employes WHERE nom='toto'
UNION ALL SELECT nom, mdp FROM employes -- '
```

→ **Préparation** pour placer les paramètres dans les requêtes

→ Sinon, **échapper** ou **retirer** les caractères dangereux

Table des matières

Frameworks

- Ensemble de fonctions et d'outils, organisé autour d'un langage, pour les applications Web
- Intégration AJAX, production de code JavaScript…
- MVC :

Modèle La structure des données de l'application et les fonctions pour les manipuler

Vue La présentation des données destinée au client

Contrôleur Le contrôle de l'interaction avec les données du modèle à travers la vue

ORM

- Object Relational Mapping
- Les frameworks Web utilisent souvent la programmation **objet**
- **Persistence** des objets dans une base de données relationnelle
- Ne concerne pas les **méthodes** !
- Historiquement : tentatives de bases de donnée **objet**

Exemple d'un ORM (Django)

Définir une classe (table) avec des attributs :

```
from django.db import models
class Blog(models.Model):
    name = models.CharField(max_length=100)
    tagline = models.TextField()
```

Créer un objet (insérer un enregistrement) :

```
b = Blog(name='Beatles', tagline='Latest Beatles news.')
b.save()
```

Récupérer un objet (faire une requête) :

```
b = Blog.objects.filter(name='Beatles')
```

Templates

- Modèles avec **champs** de Pages HTML
- **Exemple** (avec Jinja2) :

```
<h1>Résultats pour "{{ recherche }}"</h1>
<ul>
  {% for objet in resultats %}
    <li>
      <a href="details/{{ objet.id }}">
        {{ objet.nom }}
      </a>
    </li>
  {% endfor %}
</ul>
```

Routage des URLs

- Router suivant le chemin et la méthode
- Exemple (avec Flask) :

```
@app.route('/')
def index():
  pass # Préparer la page d'accueil

@app.route('/message/<int:message_id>')
def message(message_id):
  pass # Préparer l'affichage du message <message_id>

@app.route('/upload', methods=['POST'])
def upload():
  pass # Traiter un upload
```

CMS

- Content Management System
- Faire un site sans programmation :
  - Édition de page avec un texte riche, ou langages simplifiés (Markdown, Textile, BBCode…)
  - Hébergement d'images, vidéos, etc.
  - Gestion d'utilisateurs
  - Choix du thème graphique
- Différents types :

Wikis (contrôle de version, massivement éditable) : MediaWiki, MoinMoin, PmWiki…

Forums phpBB, PunBB, Phorum, vBulletin…

Blogs WordPress, Movable Type, Drupal, Blogger…

QA (comme StackOverflow) : Shapado, OSQA, AskBot

Commerce Magento, PrestaShop…

Parts de marché

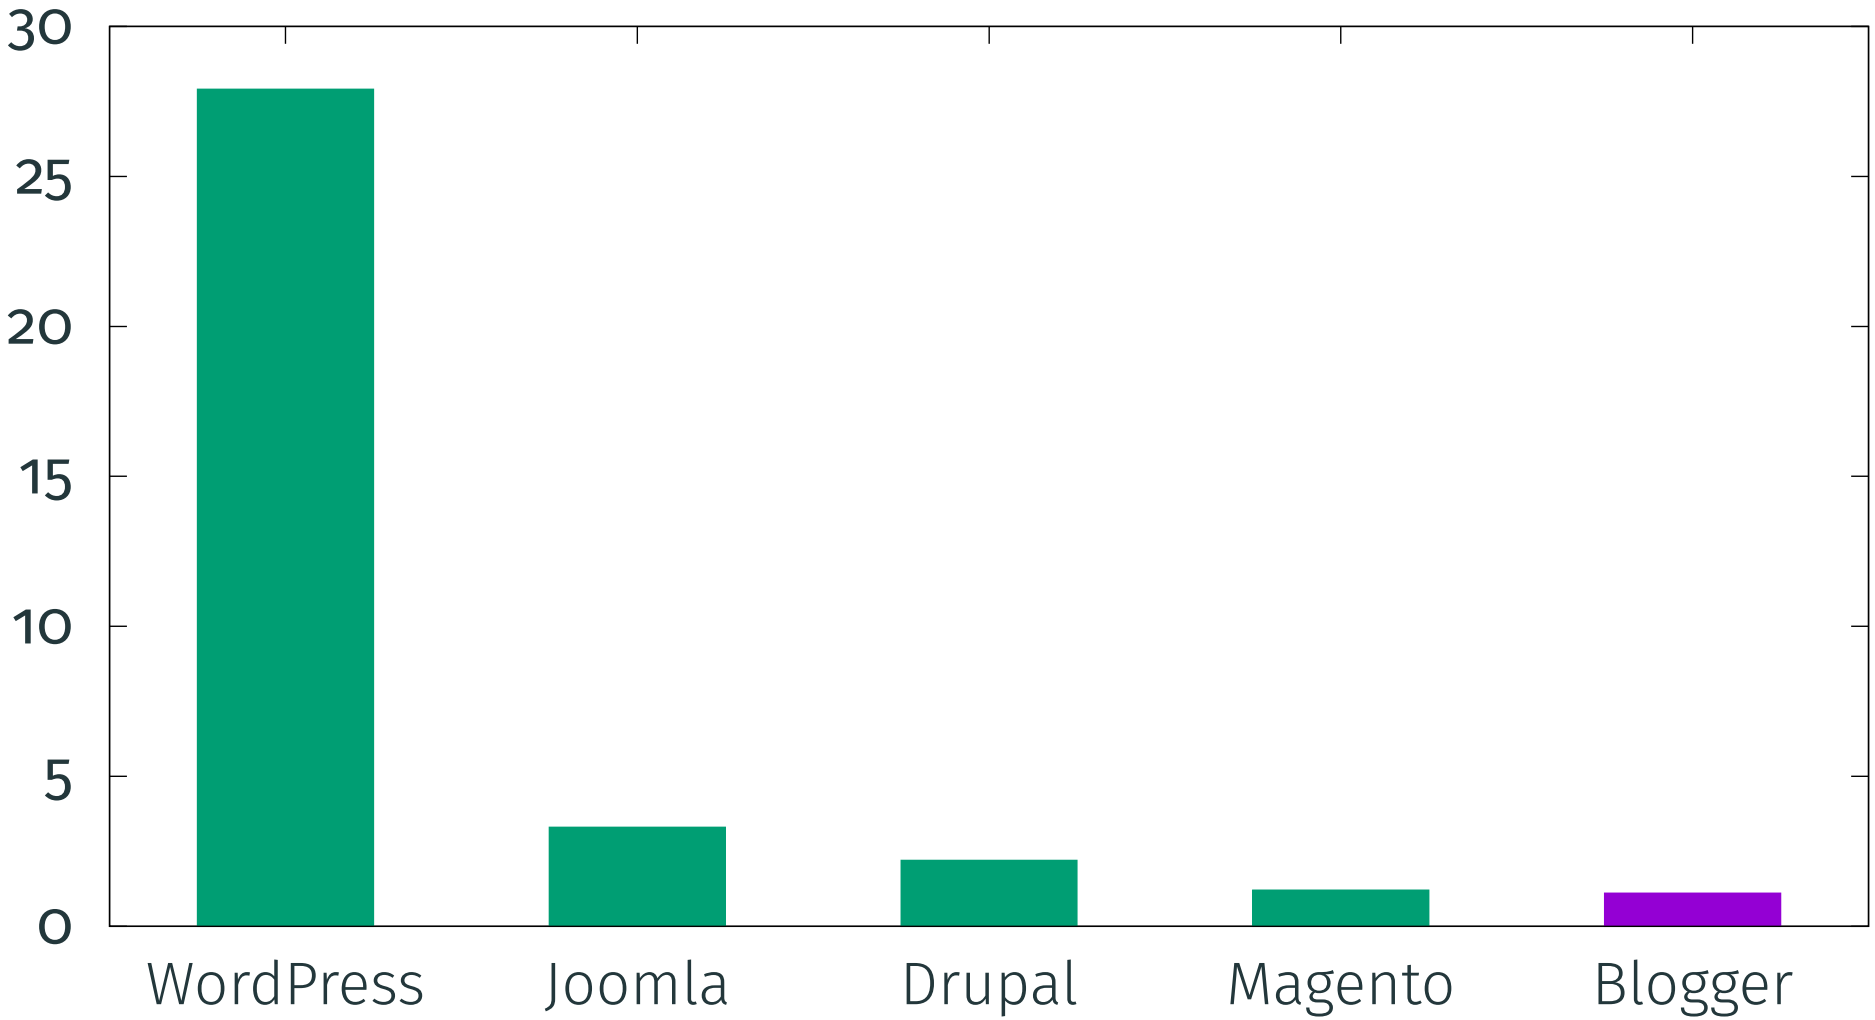

Sites avec chaque CMS (avril 2017) ; tous en PHP sauf Blogger.

Source : https://w3techs.com/technologies/overview/content_management/all

Identifier les technologies serveur

Sur le client, le code HTML, JavaScript, CSS est accessible (modulo minification et obfuscation). Sur le serveur, on n'a rien !

- `whois` : base de données fournissant (souvent) des infos sur le propriétaire d'un nom de domaine
- Localisation géographique des IP des serveurs
- `traceroute`, pour connaître le chemin réseau vers un hôte
- Outils de scan (`nmap`) pour localiser les machines et identifier le système d'exploitation (fingerprinting)
- Header `Server`, possiblement faux
- Forme des identifiants de session, cookies…
- Chemins d'accès et extensions : `.php`, `.asp`, …
- Commentaires dans le code HTML

→ Utilisé par les pirates pour identifier des services vulnérables

Table des matières

Comment se faire héberger un site Web

- Les fournisseurs d'accès proposent souvent un hébergement
- Souvent, support PHP et MySQL (et contenu statique)
- Espace disque limité
- Généralement, on utilise un client FTP pour envoyer les pages PHP et le contenu statique aux serveurs du FAI
- PHP souvent limité pour éviter les abus : pas de requêtes, envoi de courriels limité, temps de calcul et mémoire limités…
- En pratique, solution peu pérenne pour les services atypiques ou excessivement gourmands

Infrastructure d'hébergement

- **Serveur** : machine qui reste allumée pour répondre aux requêtes
- **Centre de données** : local pour serveurs avec une bonne connexion, alimentation électrique, climatisation, sécurité physique…
- Serveurs **virtuels** : machine virtualisée, imite une vraie machine
- **Cloud** : location simple à grande échelle de machines
  - → Possibilité d'ajuster le nombre de machines selon la charge
- **Content delivery network** : services de proxy intermédiaire
- **Répartition de charge** entre plusieurs machines
  - → Au niveau DNS : géographique et round-robin
  - → Au niveau logiciel

Comment héberger un site Web soi-même

- Louer un nom de domaine (environ 15 euros par an)
- Avoir un serveur. Plusieurs choix :
  - Machine personnelle : de préférence IP fixe et bon upload
    - → Abonnement Internet personnel
    - → Consommation électrique : 100 watts = 10 euros par mois
  - Virtual private server
    - → quelques euros par mois
  - Dédié
    - → quelques euros par mois aussi…
  - Machine personnelle mais en louant bande passante et espace dans une baie chez un centre de données
- Configurer SSH pour se connecter à la machine, l'administrer et y transférer des fichiers
- Installer un serveur Web
- Installer éventuellement un CMS…

Un exemple concret : Wikimedia

- `wikipedia.org`, 5e site le plus visité au monde en 2018.[3]
- Organisation caritative, environ 280 employés en 2017
- 81.9 millions de dollars de revenu en 2016 (surtout des dons)
- Coûts techniques en 2016 : quelques millions de dollars
- À peu près un millier de serveurs au total (2013)

3. `http://www.alexa.com/topsites`

Statistiques générales

- 134 000 utilisateurs actifs sur `en.wikipedia.org` [4]
- Près de 1000 éditions par minute au total [5]
- 17 milliards de pages vues par mois (robots non inclus) :
  - La moitié sur mobile en avril 2017 [6]
  - 8 milliards pour `en.wikipedia.org`
  - 750 millions pour `fr.wikipedia.org` [7]
  - Environ 7 000 par seconde en moyenne mais pointes à 50 000 [8]
- 60 millions de visiteurs uniques par jour [9]

4. `https://en.wikipedia.org/wiki/Wikipedia:Wikipedians#Number_of_editors`
5. `https://grafana.wikimedia.org/dashboard/db/edit-count?refresh=5m&orgId=1`
6. `https://stats.wikimedia.org/EN/TablesPageViewsMonthlyMobile.htm` – mais voir aussi `https://analytics.wikimedia.org/`
7. `https://analytics.wikimedia.org/dashboards/reportcard/#pageviews-july-2015-now/monthly-pageviews-2015-now`
8. `https://arstechnica.com/information-technology/2008/10/wikipedia-adopts-ubuntu-for-its-server-infrastructure/`
9. `https://analytics.wikimedia.org/dashboards/reportcard/#daily-unique-devices/daily-unique-devices`

Infrastructure générale

- Centres de données :
  - → Site principal : Ashburn, Virginia (Equinix)
  - → Pour l'Europe (réseau et cache), Amsterdam (EvoSwitch, Kennisnet)
  - → Cache : San Francisco (United Layer), Singapour (Equinix)
  - → Autres sites : Dallas, Chicago
  - → Centre de données de secours : Carrollton, Texas (CyrusOne)
- Serveurs Dell sous Ubuntu [10] et Debian
- `puppet` pour gérer la configuration des serveurs
- Logiciels de monitoring : Icinga, Grafana
  - → `grafana.wikimedia.org`
  - → `status.wikimedia.org`

10. `https://insights.ubuntu.com/2010/10/04/wikimedia-chooses-ubuntu-for-all-of-its-servers/`

Tâches principales (chiffres en 2013)

- Logiciel de gestion du wiki : **MediaWiki**, en PHP
- Serveur **Apache**, utilise HHVM [11]
  - → **192** machines (à Ashburn)
- Base de données : **MariaDB**
  - → **54** machines pour la base de données
  - → **10** machines de stockage avec 12 disques de 2 TB en RAID10
- Stockage de fichiers distribué : **Ceph** (anciennement **Swift**)
  - → **12** serveurs
- Serveurs de tâches asynchrones (base de données NoSQL **Redis**)
  - → **16** serveurs

11. https://blog.wikimedia.org/2014/12/29/how-we-made-editing-wikipedia-twice-as-fast/

Caches (chiffres de 2013)

- Squid
  - → 8 machines pour le multimédia
  - → 32 machines pour le texte
- Varnish
  - → 8 machines
- Invalidation du cache avec MediaWiki
- Memcached entre MediaWiki et la base de données
  - → 16 machines

→ 90% du trafic n'utilise que le cache et non Apache.[12]

12. https://blog.wikimedia.org/2013/01/19/wikimedia-sites-move-to-primary-data-center-in-ashburn-virginia/

Autres services (chiffres de 2013)

- Proxies de terminaison SSL avec **nginx** :
  → 9 machines
- **Load balancing** avec LVS (Linux Virtual Server) :
  → 6 serveurs
- **Indexation** pour la fonction de recherche :
  Lucene 25 serveurs
  Solr 3 serveurs
- **Redimensionnement** de fichiers multimédia :
  Images 8 serveurs
  Vidéos 2 serveurs
- **Statistiques** : 27 serveurs
- **Traitement des paiements en ligne** : 4 serveurs
- Serveurs DNS, services divers, snapshots, etc.

Exemple de rack (2015)

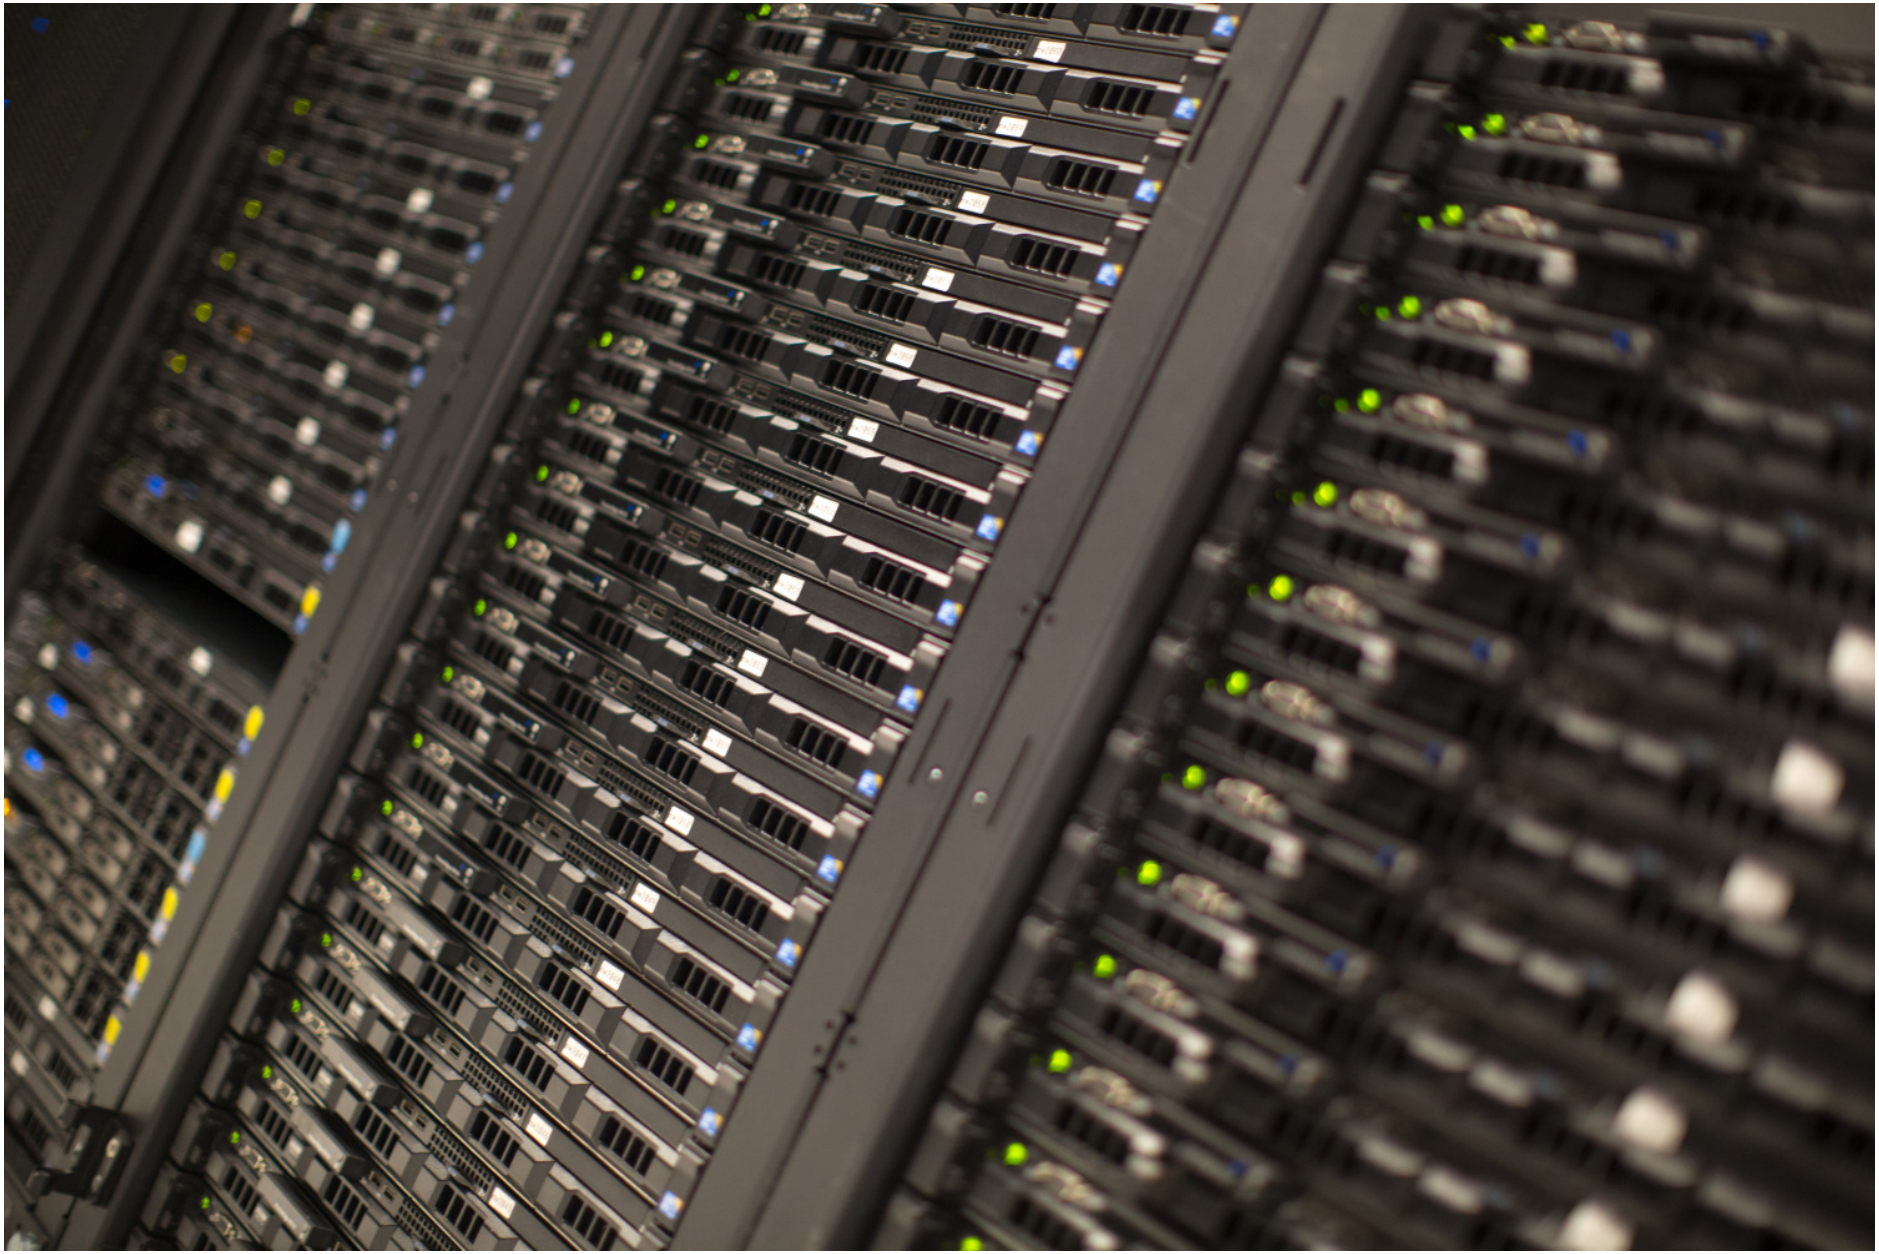

Image credits : `https://meta.wikimedia.org/wiki/File:Wikimedia_Foundation_Servers_2015-90.jpg`

Crédits

- Matériel de cours inspiré de notes par Pierre Senellart
- Merci à Pierre Senellart pour sa relecture
- Transparent 3 : chiffres Netcraft `https://news.netcraft.com/archives/category/web-server-survey`, graphe arichnad, licence CC-BY-SA, cf `https://commons.wikimedia.org/wiki/File:Usage_share_of_web_servers_(Source_Netcraft).svg`