Technologies du Web
Master COMASIC
Technologies côté serveur

Antoine Amarilli [1]

27 novembre 2014

1. Matériel de cours inspiré de notes par Pierre Senellart. Merci à Pierre Senellart pour sa relecture.

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. (Cependant, en 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

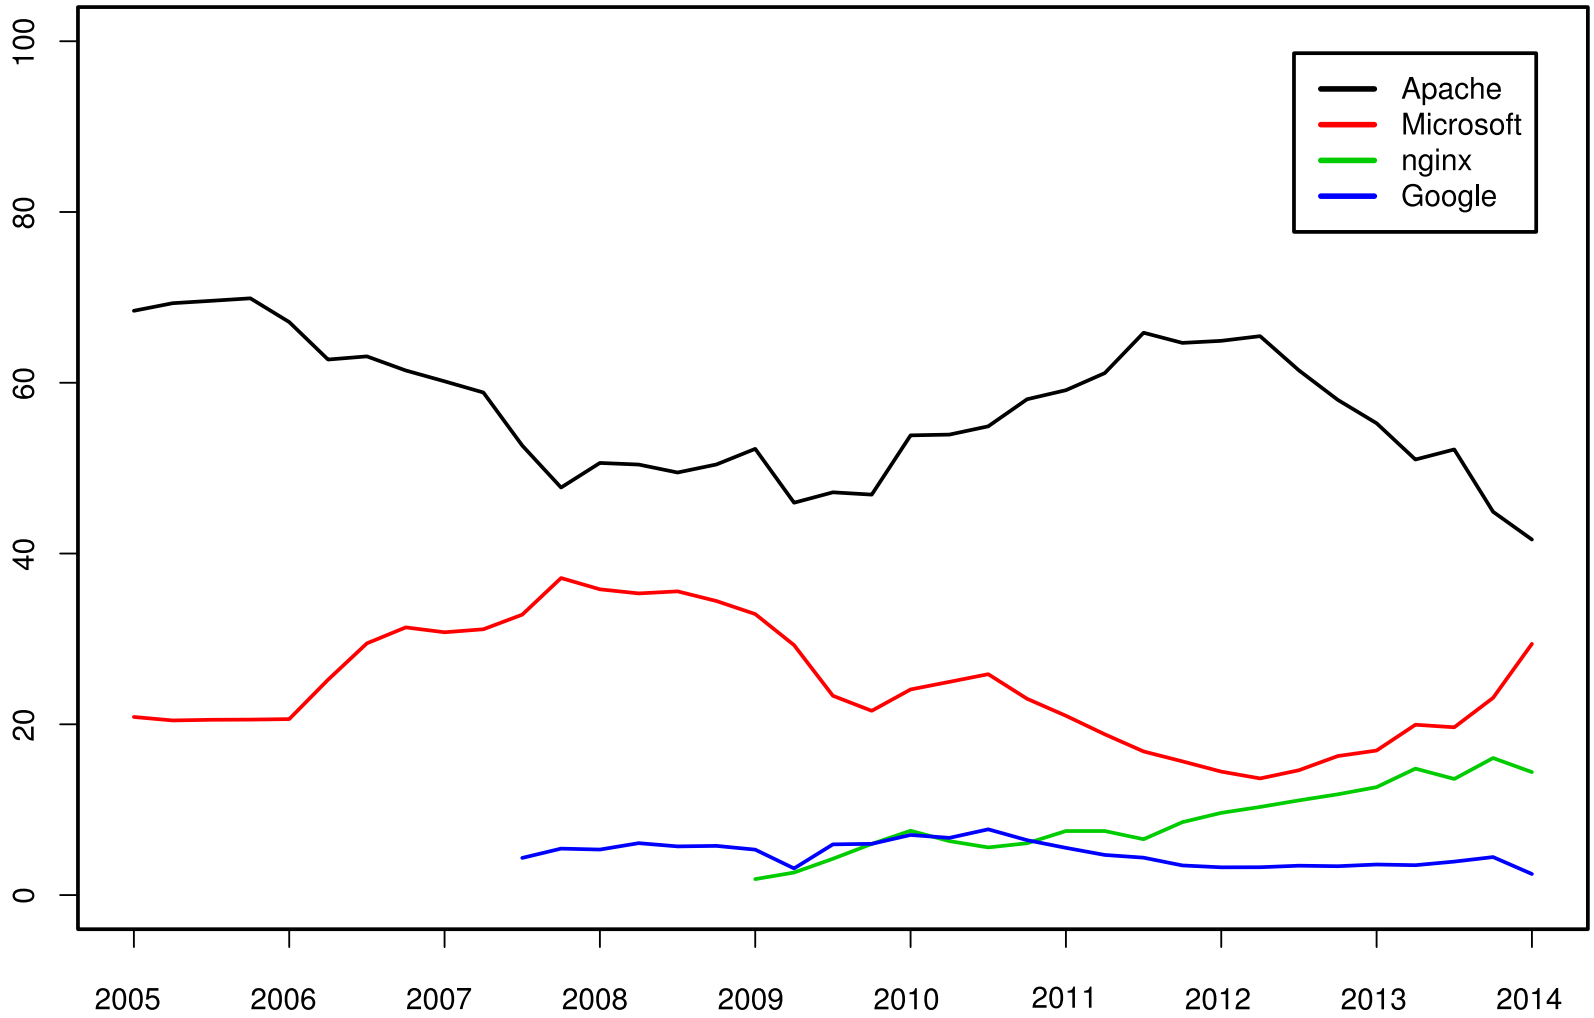

Source : Netcraft.

Logs

- Souvent, le serveur Web loggue toutes les requêtes traitées !
- NCSA Common log format :
  - Adresse IP du client
  - Identité `ident` (obsolète)
  - Identité authentification HTTP (rarement utile)
  - Date et heure de fin de traitement
  - Première ligne de la requête HTTP
  - Code d'état retourné au client
  - Taille (octets) de la réponse
- Ajouts fréquents :
  - `User-Agent` pour identifier le client
  - `Referer` pour connaître la page précédente.

```
208.115.113.88 - - [22/Jan/2012:06:27:00 +0100]
"GET /robots.txt HTTP/1.1" 404 266 "-"
"Mozilla/5.0 (compatible; Ezooms/1.0; ezooms.bot@gmail.com)"
```

Utilisation des logs

- Pages les plus visitées.
- Chemin sur le site, temps passé sur les pages, entrées, sorties (mais avec les onglets ?)
- Distinguer humains et robots (pas de garanties !)
- Emplacement géographique des visiteurs
- Mots-clés saisis dans les moteurs de recherche
- Liens vers son site
- Nombre d'abonnés à un flux RSS dans `User-Agent`.
- Spam dans `Referer`
- Et plus ?
  - Logiciels pour exploiter directement les logs du serveur.
  - Tracking en PHP.
  - Tracking tiers en JavaScript (Google Analytics).
  - Tracking possible du pointeur de la souris en JavaScript, etc.

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 par 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 [2].
- 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>
```

2. http://www.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...
- Promeut 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.
  - → Cependant, compilation vers C++ (HipHop, pour 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.
- → Orienté événements, et VM performante.

Python Frameworks Web : Django, CherryPy, Flask.

Ruby Frameworks Web : Ruby on Rails (influent !), 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.
IBM 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. Fork : MariaDB.
PostgreSQL	Libre, concurrent de MySQL. Lancé en 1995.

SGBDs, parts de marché en entreprise (cumulatives)

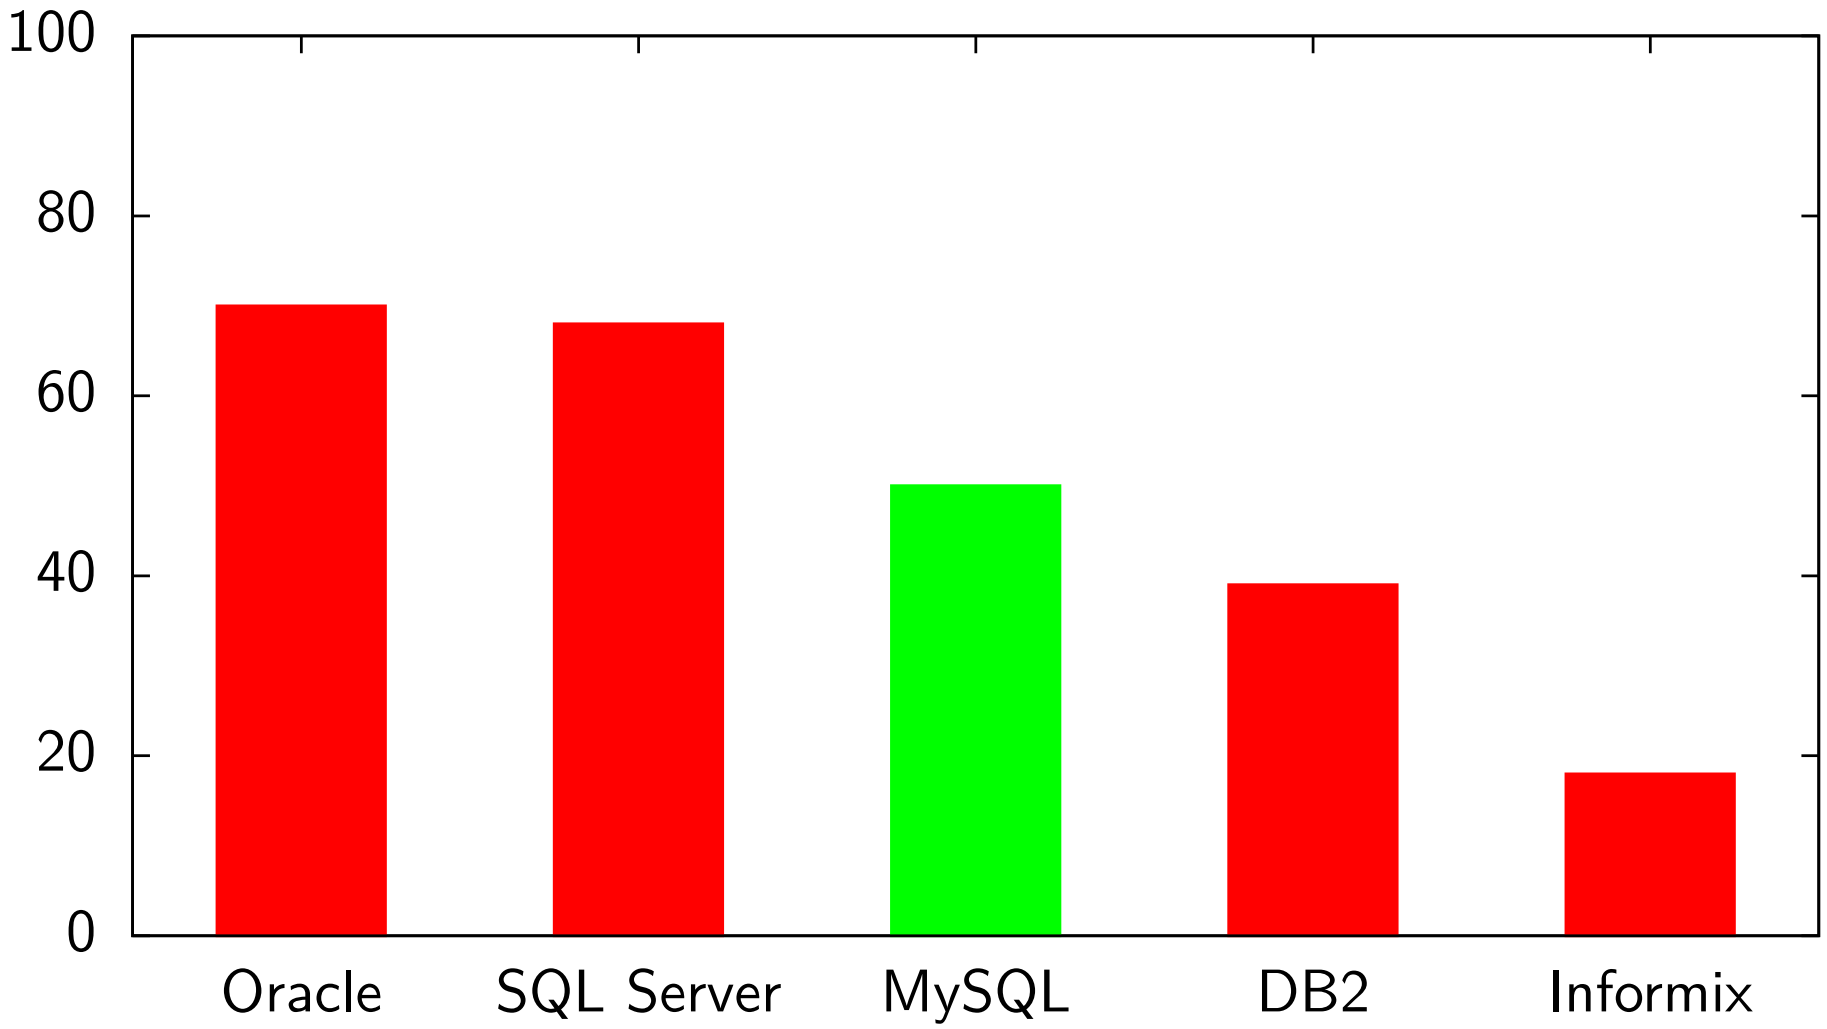

Source : étude Gartner de 2008 citée dans
`https://www.mysql.com/why-mysql/marketshare/`

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 inconsistances.
- 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[3] : MongoDB, utilisé par Craigslist, le CERN, Shutterfly, Foursquare, etc.

3. `http://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

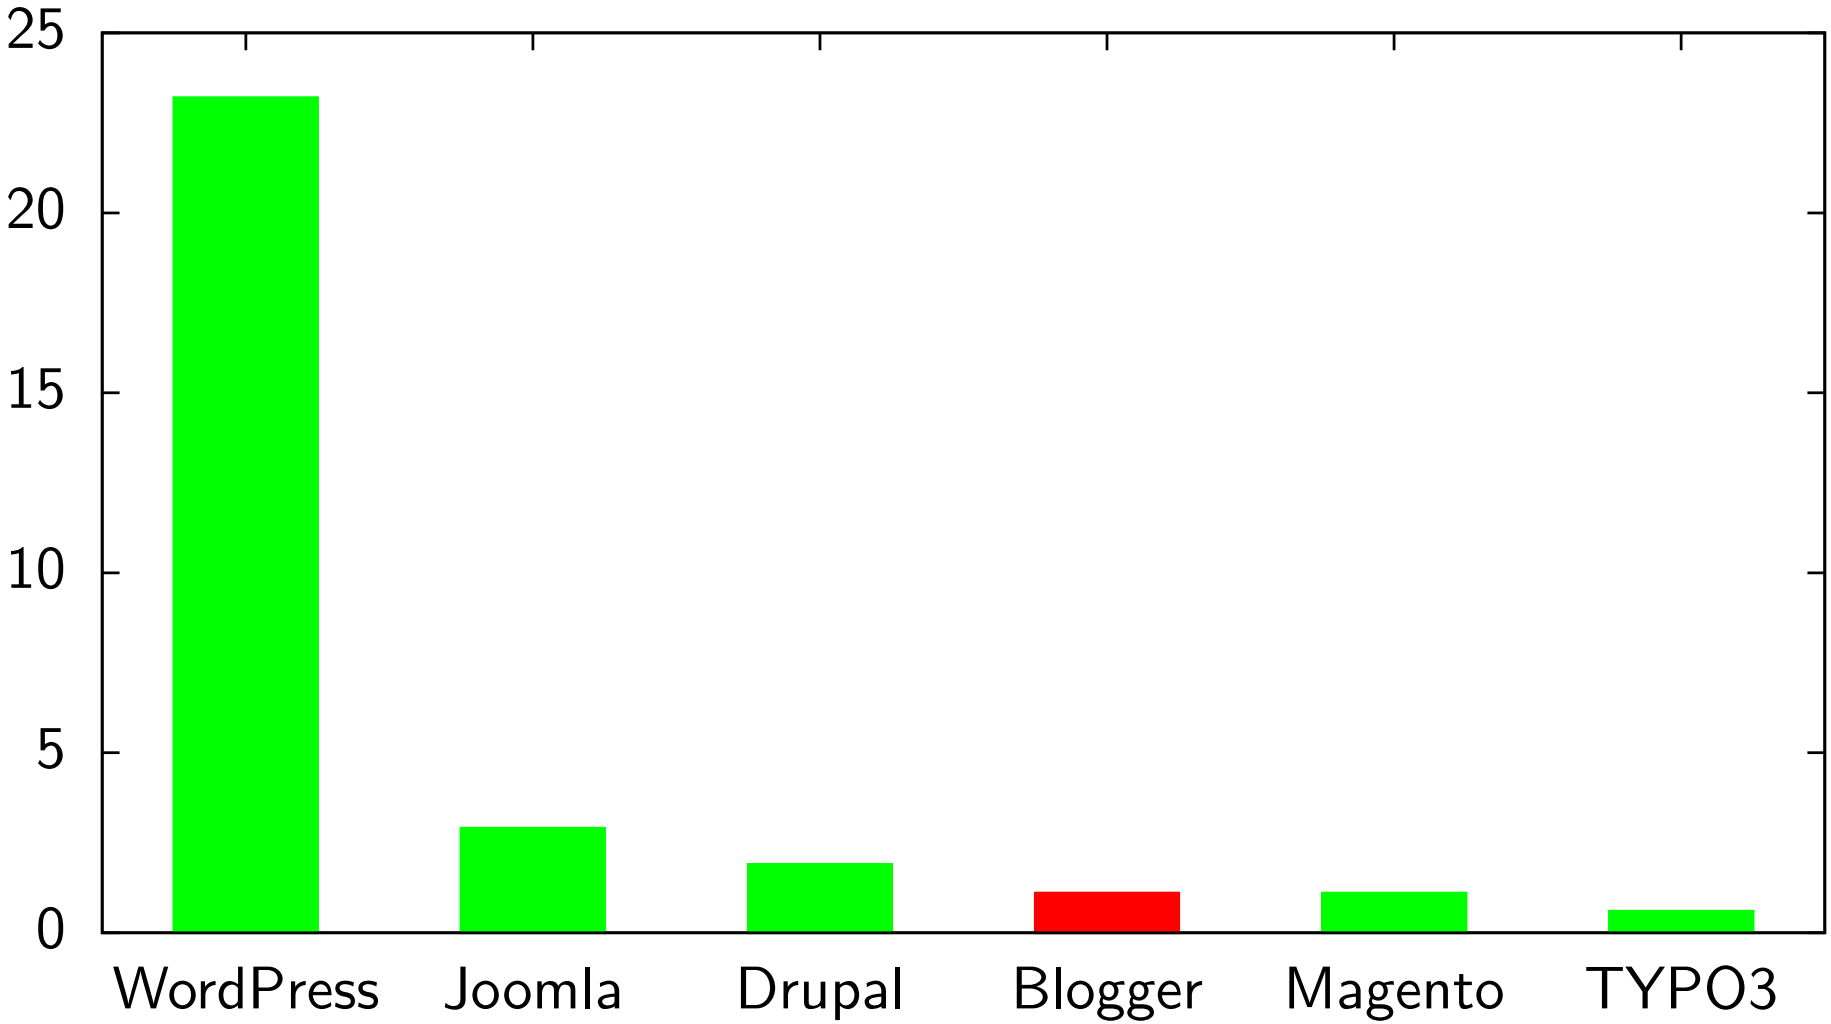

Sites avec chaque CMS (nov. 2014) ; tous en PHP sauf Blogger.

Source : http://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 toujours allumée pour répondre aux requêtes.
- Datacenter : local pour serveurs avec une bonne connexion, alimentation électrique, climatisation, sécurité physique...
- Serveurs virtuels : machine virtualisée qui imite une machine physique
- 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 10 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 datacenter.
- 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`, 6e site le plus visité au monde.[4]
- Organisation caritative, 208 employés en juillet 2014.
- 75 000 utilisateurs actifs[5], >10 millions d'éditions par mois.
- 50 millions de dollars de revenu en 2013 (surtout des dons).
- Coûts techniques en 2011 : quelques millions de dollars.
- À peu près un millier de serveurs au total.
- À peu près 20 milliards de pages vues par mois :
  - 5 milliards sur mobile
  - 10 milliards seulement pour `en.wikipedia.org`
  - 1 milliard pour `fr.wikipedia.org`
  - 8 000 par seconde en moyenne mais pointes à 50 000.[6]
- 500 millions de visiteurs uniques par mois.

4. `http://www.alexa.com/topsites`
5. `http://reportcard.wmflabs.org/`
6. `http://arstechnica.com/information-technology/2008/10/wikipedia-adopts-ubuntu-for-its-server-infrastructure/`

Infrastructure générale

- Data centers :
  - → Site principal : Ashburn, Virginia (Equinix).
  - → Pour l'Europe (réseau), Amsterdam (EvoSwitch, Kennisnet).
  - → Anciens caches et serveurs : Séoul, Paris, Tampa (Floride)
  - → Cache : San Francisco (United Layer)
  - → Failover sur Carrollton, Texas (CyrusOne)
- Serveurs Dell sous Ubuntu.[7]
- puppet pour gérer la configuration des serveurs.
- Logiciels de monitoring : Ganglia, Icinga, GDash.
  - → `ganglia.wikimedia.org`
  - → `gdash.wikimedia.org`

7. `http://www.ubuntu.com/products/casestudies/wikimedia`

Tâches principales (chiffres en 2013)

- Logiciel de gestion du wiki : MediaWiki, en PHP.
- Serveur Apache, HipHop envisagé pour PHP.
  → 192 machines (à Ashburn)
- Base de données : MariaDB (fork de MySQL).
  → 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 pour les travaux asynchrones (base de données NoSQL Redis)
  → 16 serveurs

Caches

- 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. [8]

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

Autres services

- 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

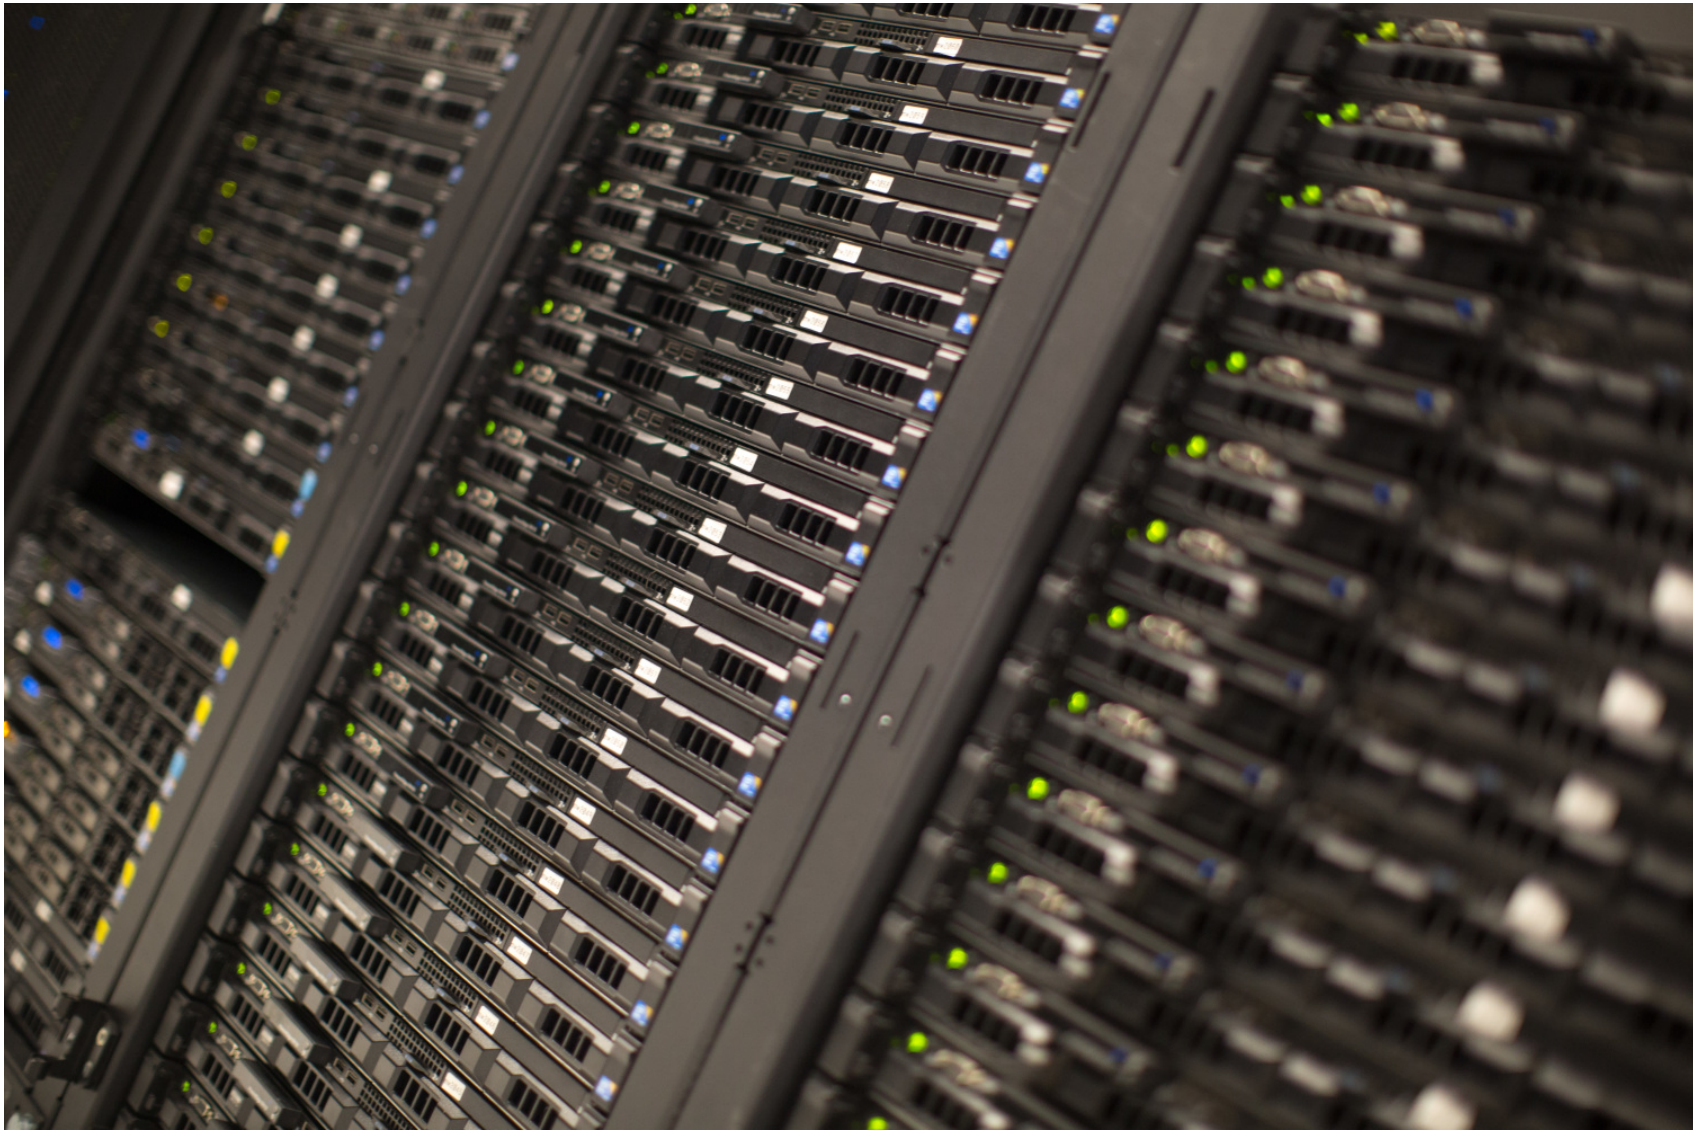

Image credits : https://meta.wikimedia.org/wiki/File:Wikimedia_Foundation_Servers_2015-90.jpg