Données sur le Web

Dan VODISLAV

CY Cergy Paris Université

Master Recherche M2 SIC

Internet et Web

- ***Internet*** = réseau *physique* d'ordinateurs
- ***Web*** (WWW, World Wide Web) = réseau *logique* de hyper-documents (documents avec des liens)
  - Documents statiques (fixes) ou dynamiques (produits par un programme)
  - Web publique et webs privés
  - Chaque document (page web) identifié par une URL
- ***URL*** (Uniform Resource Locator)

`https://www.exemple.org:443/chemin/vers/page?p1=v1&p2=v2#part`

  - Protocole: `http`, `https`, `ftp`, …
  - Nom serveur: ici `www.exemple.org`
  - Port: par défaut 80 pour http, 443 pour https, …
  - Chemin et nom du document: ici `chemin/vers/page`
  - Paramètres requête (documents dynamiques): ici `?p1=v1&p2=v2`
  - Fragment: partie du document, ici `#part`

HTML, HTTP

- Format pour les pages web: HTML
  - Texte + balises de mise en forme
- HTTP: protocole client-serveur pour le web, basé sur TCP/IP
  - HTTPS: version sécurisée de HTTP (cryptage, authentification, …)

```
<html>
  <head><title>Titre de la page</title></head>
  <body><h1>Titre de la section</h1>
    <p>Paragraphe de texte <i>en italique</i> ou  <b>en gras</b>  etc. </p>
    <ul>
      <li>Une ligne</li>
      <li>Ligne avec <a href="http://a.b.c/page.html">lien</a></li>
    </ul>
  </body>
</html>
```

Titre de la section

Paragraphe de texte *en italique* ou **en gras** etc.

- Une ligne
- Ligne avec lien

Données sur le web

- Organisation: documents
  - Graphe d'hyperliens
- Type de données: texte
  - Structuration possible
  - XML, JSON: structure d'arbre
- Recherche, interrogation
  - Par mots-clés
  - Requêtes booléennes
  - Requêtes avec classement

Interrogation du web

- Problème: comment indexer le texte des documents pour être capable de répondre efficacement à des requêtes mots-clés?
- Exemple (en anglais): ensemble de 7 documents

  d1: The jaguar is a New World mammal of the Felidae family.

  d2: Jaguar has designed four new engines.

  d3: For Jaguar, Atari was keen to use a 68K family device.

  d4: The Jacksonville Jaguars are a professional US football team.

  d5: Mac OS X Jaguar is available at a price of US $199 for Apple's new "family pack".

  d6: One such ruling family to incorporate the jaguar into their name is Jaguar Paw.

  d7: It is a big cat.

Pré-traitement du texte

- Étapes de pré-traitement dépendantes de l'application et de la langue des documents
  - Découpage en mots ("tokenization")
  - Lemmatisation ("stemming")
  - Élimination des mots fréquents ("stop words")

Découpage en mots

- Le mot est l'unité de recherche
- Le découpage en mots n'est pas si simple que ça!
  - Dans certaines langues, les mots ne sont pas séparés par des espaces (chinois, japonais)
  - Traitement spécial pour les acronymes, les abréviations, les élisions, les nombres, les URLs, les adresses mail, les unités de mesure, etc.
  - Mots composés (hostname, host-name, host name): les garder ensemble ou les séparer en mots?
    - Parfois très compliqué (Allemand): analyse lexicale et linguistique
- Dans cette étape: on enlève la ponctuation et on passe en minuscules

Exemple découpage en mots

d1: the$_1$ jaguar$_2$ is$_3$ a$_4$ new$_5$ world$_6$ mammal$_7$ of$_8$ the$_9$ felidae$_{10}$ family$_{11}$

d2: jaguar$_1$ has$_2$ designed$_3$ four$_4$ new$_5$ engines$_6$

d3: for$_1$ jaguar$_2$ atari$_3$ was$_4$ keen$_5$ to$_6$ use$_7$ a$_8$ 68k$_9$ family$_{10}$ device$_{11}$

d4: the$_1$ jacksonville$_2$ jaguars$_3$ are$_4$ a$_5$ professional$_6$ us$_7$ football$_8$ team$_9$

d5: mac$_1$ os$_2$ x$_3$ jaguar$_4$ is$_5$ available$_6$ at$_7$ a$_8$ price$_9$ of$_{10}$ us$_{11}$ \$199$_{12}$ for$_{13}$ apple's$_{14}$ new$_{15}$ family$_{16}$ pack$_{17}$

d6: one$_1$ such$_2$ ruling$_3$ family$_4$ to$_5$ incorporate$_6$ the$_7$ jaguar$_8$ into$_9$ their$_{10}$ name$_{11}$ is$_{12}$ jaguar$_{13}$ paw$_{14}$

d7: it$_1$ is$_2$ a$_3$ big$_4$ cat$_5$

Lemmatisation

- Considérer la racine (lemme) des mots, afin de "fusionner" tous les mots de la même famille
  - Pas toutes les applications souhaitent cela!
  - En cherchant *enfant* on retrouve *enfants* ou *enfance*
  - Différents degrés de lemmatisation
  - Il est possible de construire plusieurs index, avec des techniques de lemmatisation différentes
- Types de lemmatisation
  - Morphologique
  - Lexicale
  - Phonétique

Types de lemmatisation

- Morphologique: enlever les terminaisons
  - Pluriel, genre, temps, mode, …
  - Pas toujours facile: "*Les poules du couvent couvent*."
  - En anglais c'est plus facile (terminaisons régulières, avec quelques exceptions bien répertoriées), mais il reste des ambiguïtés
- Lexicale
  - Termes d'une même famille
  - En anglais: algorithme de Porter, basé sur des critères morphologiques (!)
    - Pas toujours de bons résultats (ex. university, universal → univers)
  - Couplage avec des dictionnaires pour regrouper aussi les synonymes
- Phonétique
  - Regroupe des mots qui se prononcent pareil (ou presque pareil)
  - Objectif: traiter les fautes de frappe/orthographe
  - Assez grossier

Exemple lemmatisation

d1: the$_1$ jaguar$_2$ be$_3$ a$_4$ new$_5$ world$_6$ mammal$_7$ of$_8$ the$_9$ felidae$_{10}$ family$_{11}$

d2: jaguar$_1$ have$_2$ design$_3$ four$_4$ new$_5$ engine$_6$

d3: for$_1$ jaguar$_2$ atari$_3$ be$_4$ keen$_5$ to$_6$ use$_7$ a$_8$ 68k$_9$ family$_{10}$ device$_{11}$

d4: the$_1$ jacksonville$_2$ jaguar$_3$ be$_4$ a$_5$ professional$_6$ us$_7$ football$_8$ team$_9$

d5: mac$_1$ os$_2$ x$_3$ jaguar$_4$ be$_5$ available$_6$ at$_7$ a$_8$ price$_9$ of$_{10}$ us$_{11}$ \$199$_{12}$ for$_{13}$ apple$_{14}$ new$_{15}$ family$_{16}$ pack$_{17}$

d6: one$_1$ such$_2$ rule$_3$ family$_4$ to$_5$ incorporate$_6$ the$_7$ jaguar$_8$ into$_9$ their$_{10}$ name$_{11}$ be$_{12}$ jaguar$_{13}$ paw$_{14}$

d7: it$_1$ be$_2$ a$_3$ big$_4$ cat$_5$

Élimination des mots fréquents

- Les mots fréquents se trouvent partout et ne distinguent pas les documents les uns par rapport aux autres
  - Leur élimination ne modifie pas significativement les résultats des requêtes
- Avantage: le nombre de mots du texte et la taille de l'index diminuent sensiblement
- Mots fréquents:
  - Articles: le, la, un, une, des, …
  - Verbes fonctionnels: être, avoir, faire, …
  - Conjonctions: et, ou, que, …
  - etc.

Exemple élimination mots fréquents

d1: jaguar$_2$ new$_5$ world$_6$ mammal$_7$ felidae$_{10}$ family$_{11}$

d2: jaguar$_1$ design$_3$ four$_4$ new$_5$ engine$_6$

d3: jaguar$_2$ atari$_3$ keen$_5$ 68k$_9$ family$_{10}$ device$_{11}$

d4: jacksonville$_2$ jaguar$_3$ professional$_6$ us$_7$ football$_8$ team$_9$

d5: mac$_1$ os$_2$ x$_3$ jaguar$_4$ available$_6$ price$_9$ of$_{10}$ us$_{11}$ \$199$_{12}$ apple$_{14}$ new$_{15}$ family$_{16}$ pack$_{17}$

d6: one$_1$ such$_2$ rule$_3$ family$_4$ to$_5$ incorporate$_6$ jaguar$_8$ their$_{10}$ name$_{11}$ jaguar$_{13}$ paw$_{14}$

d7: big$_4$ cat$_5$

Index inversé

- Index de tous les mots (termes) retenus après le pré-traitement, avec pour chacun la liste de documents où il apparaît
- Stockage
  - Petite échelle: sur disque, avec des mécanismes de mémoire virtuelle
  - Grande échelle: *cluster de machines*, avec hachage pour trouver la machine qui stocke l'entrée pour un mot donné
- Mise à jour
  - Coûteuse, réalisée généralement par lots (batch) et non pas individuellement

Exemple index inversé

family: *d1, d3, d5, d6*
football: *d4*
jaguar: *d1, d2, d3, d4, d5, d6*
new: *d1, d2, d5*
rule: *d6*
us: *d4, d5*
world: *d1*
…

Positions des mots dans le document

- Utiles pour les requêtes de type "phrase" (plusieurs mots qui doivent se suivre dans l'ordre) ou des opérateurs comme NEAR
- Rajoutées à l'index pour chaque document
  - Un document peut avoir plusieurs occurrences du mot

family: *d1/11, d3/10, d5/16, d6/4*
football: *d4/8*
jaguar: *d1/2, d2/1, d3/2, d4/3, d5/4, d6/8+13*
new: *d1/5, d2/5, d5/15*
rule: *d6/3*
us: *d4/7, d5/11*
world: *d1/6*
…

Requêtes booléennes

- Trouver les documents qui contiennent les mots de la requête
- Un seul mot: liste de documents dans l'index inversé
- Plusieurs mots

  Ex. *(jaguar AND new AND NOT family) OR cat*
  - On cherche les listes de documents pour les mots de la requête
  - Opérations sur les listes, suivant l'opérateur logique:
    - *AND:* intersection
    - *OR*: union
    - *AND NOT*: différence
- Requêtes impliquant la position dans le texte
  - Pareil, mais on filtre par rapport à la position des mots

Modèle vecteur

- Réponse: documents *similaires* à une requête
- Méthode
  - Dans chaque document une partie des mots sont indexés
    - *n*: nombre total de mots indexés dans le système
  - Un document *d* devient un point (vecteur) dans un espace à *n* dimensions
    - à chacun des mots (*i*) est associé un poids (une coordonnée) $1 \geq w_{id} \geq 0$
  - Requête *q* : point (vecteur): $(w_{1q},\ldots,w_{iq},\ldots,w_{nq})$
  - Réponse: les documents (points) les plus proches du point requête
- Avantage: ordonnancement des réponses par similarité décroissante
- Modèle booléen: les poids sont 0 / 1 et l'appartenance d'un document au résultat est stricte

Modèle vecteur : similarité

- Exemples de mesures de similarité
  - Distance euclidienne
  - On préfère: cosinus de l'angle entre les deux vecteurs
    - $\text{sim}(d, q) = \cos(\theta) = \sum (w_{id} * w_{iq}) / (\text{norme}(d) * \text{norme}(q))$

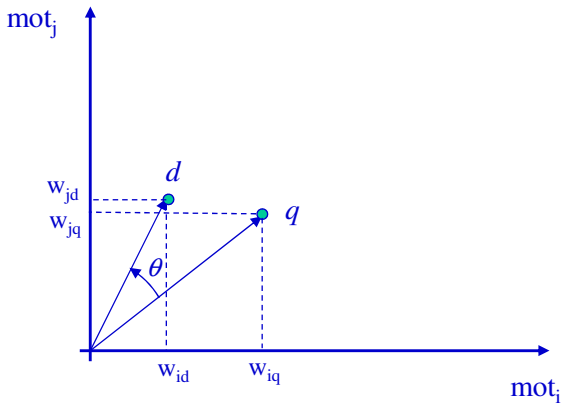

Calcul des poids: tf/idf

- Fréquence d'un terme (mot) dans un document
  - *tf* : « term frequency »
  - exprime l'importance du terme (*i*) pour caractériser le document (*d*)

  $\mathbf{tf_{id} = freq_{id} / max_t(freq_{td})}$
- Inverse de la fréquence d'un terme dans un corpus de documents
  - *idf* : « inverse document frequency »
  - exprime la capacité du terme (*i*) à filtrer parmi les documents du corpus
    - corpus de *N* documents, le terme *i* apparaît dans n_i documents

  $\mathbf{idf_i = \log((N+1)/n_i)}$
- Calcul des poids : $\mathbf{w_{id} = tf_{id} * idf_i}$
  - w_{iq} : une formule similaire (avec des variantes), en considérant *q* comme un document contenant les mots de la requête

Exemple calcul tf/idf

family: *d1/11, d3/10, d5/16, d6/4*
football: *d4/8*
jaguar: *d1/2, d2/1, d3/2, d4/3, d5/4, d6/8+13*
new: *d1/5, d2/5, d5/15*
rule: *d6/3*
us: *d4/7, d5/11*
world: *d1/6*
…

- $\mathbf{tf_{jaguar,d6} = freq_{jaguar,d6} / max_t(freq_{t,d6}) = 2/2 = 1}$
  $\mathbf{tf_{rule,d6} = freq_{rule,d6} / max_t(freq_{t,d6}) = 1/2 = 0,5}$
  $\mathbf{tf_{new,d6} = freq_{new,d6} / max_t(freq_{t,d6}) = 0/2 = 0}$
- $\mathbf{idf_{jaguar} = log((N+1)/n_{jaguar}) = log(8/6) = 0,125}$
  $\mathbf{idf_{rule} = log((N+1)/n_{rule}) = log(8/1) = 0,903}$
  $\mathbf{idf_{new} = log((N+1)/n_{new}) = log(8/3) = 0,426}$
- $\mathbf{w_{jaguar,d6} = tf_{jaguar,d6} * idf_{jaguar} = 0,125}$
  $\mathbf{w_{rule,d6} = tf_{rule,d6} * idf_{rule} = 0,452}$
  $\mathbf{w_{new,d6} = 0}$

Exemple fonction de similarité avancée

- Utilisée par le moteur d'indexation textuelle Lucene
  - Requête *q*, document *d*, terme *t* de la requête *q*

$$sim(q,d) = coord(q,d) \times queryNorm(q) \times norm(d) \times \sum_{t \in q} tf(t,d) \times idf(t)^2$$

  - $tf(t,d) = \sqrt{freq(t,d)}$ (*freq(t,d)* = nb apparitions *t* dans *d*)
  - $idf(t) = 1 + \log(\frac{numDocs}{docFreq(t)+1})$ (*docFreq(t)* = nb docs où *t* apparaît)
  - $norm(d) = \frac{1}{\sqrt{numTerms(d)}}$ (*numTerms(d)* = nb termes dans *d*)
  - $coord(q,d) = \frac{numTerms(q \cap d)}{numTerms(q)}$
  - $queryNorm(q) = \frac{1}{\sqrt{\sum_{t \in q} idf(t)^2}}$

PageRank

- Mesure l'importance d'un document dans le graphe de liens
  - Probabilité d'arriver sur le document en navigant à travers les liens
  - Marche aléatoire (random walk) dans le graphe

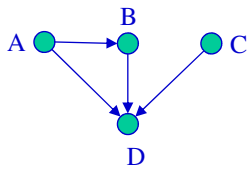

$p_D = p_A/2 + p_B + p_C$

- Problème: les nœuds sans liens sortants ou entrants
  - On rajoute une probabilité de ne suivre aucun lien, mais de « sauter » aléatoirement sur n'importe quelle page
  - Probabilité *d* de ne suivre aucun lien, donc *1-d* de suivre l'un des liens

Calcul PageRank

- Calcul du PageRank de chaque nœud
  - PageRank(*n*) = probabilité d'arriver sur le nœud *n* après un nombre infini de pas
  - Vecteur PR = (pr_i), initialisé à 1/N
    - N = nombre de nœuds dans le graphe
  - Matrice de transition L = (l_{ij})
    - $l_{ij} = 0$ si pas d'arc $n_i \rightarrow n_j$
    - $l_{ij} = 1/o_i$, où o_i = nombre d'arcs sortants de n_i
  - Vecteur unitaire U = (u_i), $u_i = 1$
  - $PR^{(k+1)} = d\ U + (1-d)\ L^T * PR^{(k)}$
  - PageRank = $\lim_{k \to \infty} PR^{(k)}$

- Utilisation du PageRank
  - Pour le classement des résultats de recherche
  - Combiné avec la similarité textuelle

XML

- XML: eXtensible Markup Lanuage
  - Langage de description de documents structurés
  - Utilisation de balises (balisage structurel)
- Standard W3C pour l'échange/publication de données sur le web
- Héritage:
  - HTML: documents publiés sur le web, mais ensemble de balises fixé, dédiées à la *présentation* du contenu → difficile à exploiter le contenu
  - Données structurées: bases de données, contenu structuré, mais mal adapté à la structure des documents web (texte, structure irrégulière)

  → XML décrit *le contenu* de façon (semi-)structurée, *flexible*, adaptée aux documents du web

Exemple

- HTML

```
<h1>Bibliographie</h1>
<ul><li>G. Gardarin, <i>XML : Des Bases de Données aux Services Web</i>, Dunod, 2003
    <li>S. Abiteboul, N. Polyzotis, <i>The Data Ring</i>, CIDR, 2007
</ul>
```

- XML

```
<bibliographie>
  <ouvrage année="2003">
    <auteur>G. Gardarin</auteur>
    <titre>XML : Des Bases de Données aux Services Web</titre>
    <éditeur>Dunod</éditeur>
  </ouvrage>
  <ouvrage année="2007">
    <auteur>S. Abiteboul</auteur>
    <auteur>N. Polyzotis</auteur>
    <titre>The Data Ring</titre>
    <conférence>CIDR</conférence>
  </ouvrage>
</bibliographie>
```

XML orienté données et orienté texte

- XML est très flexible → peut représenter à la fois des données très structurées et du texte très peu structuré
- XML orienté données

```
<inventaire>
   <produit code="AZ320">
      <nom>Ordinateur</nom>
      <prix>750</prix>
   </produit>
   <produit code="LM208">
      <nom>Chaise</nom>
      <prix>63</prix>
   </produit>
</inventaire>
```

inventaire

code	nom	prix
AZ320	Ordinateur	750
LM208	Chaise	63

- XML orienté texte

```
<description>Dans la boutique <nom>Le Bureau</nom>, située
  <adresse>25 rue de l'Oise</adresse> on peut acheter tout ce
  dont on a besoin pour son bureau: <produit> ordinateur
  </produit>, <produit> chaise </produit>, etc.
</description>
```


Formes sérialisée et arborescente

- Forme sérialisée d'un document/élément
  - Chaîne de caractères (texte) incluant balises et contenu textuel

  Exemple

```
<lettre type='court'><salutation>Bonjour!</salutation><fin>Au
revoir</fin></lettre>
```

  ou avec un peu de mise en forme

```
<lettre type='court'>
   <salutation>Bonjour!</salutation>
   <fin>Au revoir</fin>
</lettre>
```

- Forme arborescente
  - Utilisée par les applications, modèle DOM (W3C)

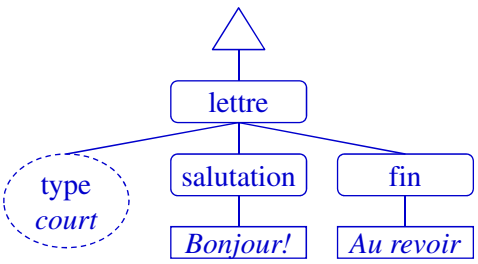

XPath

- Langage de sélection d'un ensemble de nœuds dans un document XML
  - Utilise des *expressions de chemin* pour désigner des nœuds dans l'arbre
- Une expression de chemin XPath: suite d'**étapes** à partir d'un **nœud contexte**
  `[/]étape`$_1$`/étape`$_2$`/…/étape`$_n$
- Étape = `axe::filtre[prédicat`$_1$`]…[prédicat`$_n$`]`
- Exemples
  - `/bibliographie/ouvrage/titre` : titres des ouvrages
  - `/bibliographie/ouvrage/titre/text()` : texte des titres des ouvrages
  - `//ouvrage/auteur` : auteurs des ouvrages
  - `//ouvrage[@année>2005]/titre` : titre des ouvrages après 2005
  - `//ouvrage[count(auteur)>1]/titre` : titre des ouvrages avec plus d'un auteur
  - `min(//ouvrage[auteur="S. Abiteboul"]/@année)` : année du premier ouvrage de S. Abiteboul

JSON

- JSON = JavaScript Object Notation
- Modèle pour les documents structurés
  - Pas de balises, mais des couples clé-valeur
  - Valeur
    - Simple: chaine de caractères, numérique, booléen
    - Liste de valeurs hétérogènes [ ]
    - Objet: ensemble de couples clé-valeur { }
  - Imbrication de valeurs → structure d'arbre, comme XML

```
{"ouvrage": [{"année": 2003,
              "auteur": ["G. Gardarin"],
              "titre": "XML : Des Bases de Données aux Services Web",
              "éditeur": "Dunod"},
             {"année": 2007,
              "auteur": ["S. Abiteboul", "N. Polyzotis"],
              "titre": "The Data Ring",
              "conférence": "CIDR"}
            ]
}
```

JSON

- Comparaison avec XML
  - Format plus compact que XML
  - Structure arborescente
    - XML: étiquettes sur les nœuds
    - JSON: étiquettes sur les arcs
  - Passage simple d'un modèle à l'autre
    - JSON plus adapté aux documents orientés données
  - Pas de langage de requêtes standardisé
    - Plusieurs propositions inspirés de XML
- Utilisation
  - Echange de données client-serveur dans Javascript
  - Format d'échange pour applications Web
  - Format de données pour les services Web REST

Comparaison XML-JSON