


L'algorithme PageRank



Résumé :

Thématique : **Web**

Point du programme traité :

Contenus : Moteurs de recherche : principes et usages

Capacités attendues : Mener une analyse critique des résultats fournis par un moteur de recherche.

Lieu de l'activité : En salle de classe

Matériels / logiciels utilisés : un jeu de dés

Durée de l'activité : 1h environ

Plan de la ressource :

- 1) Introduction : Comment un moteur de recherche classe les sites ?
- 2) Le principe du surfeur aléatoire
 - a. TP n°1 : jeu / étude d'un premier graphe
 - b. TP n°2 : jeu / étude d'un second graphe
 - c. TP n°3 : quelques petits problèmes...
- 3) Modification de l'algorithme
- 4) A retenir
- 5) Des chaînes de Markov aux « créations artistiques par ordinateur »
- 6) Liens avec PIX

1) Introduction : Comment un moteur de recherche classe les sites ?

Pour hiérarchiser la pertinence de site web sur un domaine, plusieurs solutions assez naturelles existent :

— On peut faire appel a une sommité (personne ou groupe de personnes) du domaine pour classer les pages. Le classement serait certes très pertinent pour ce domaine mais il faudrait solliciter un grand nombre de spécialistes de différents domaines pour obtenir un algorithme pouvant traiter des requêtes dans tous les domaines possibles et imaginables.

Il se pose aussi la difficulté de gérer le très grand nombre de pages évoquant une requête (plusieurs millions au minimum) ainsi que l'actualisation fréquente de ce classement.

— Une deuxième solution serait de demander aux internautes eux-mêmes de voter, pour chaque domaine, et de choisir le classement sur la base de ce vote, considérant, que compte-tenu du grand nombre de votants, le classement obtenu serait pertinent.

Ces deux modèles, pourtant intéressants et logiques (ils sont mis en œuvre par wikipédia), font intervenir l'humain et trouvent leur limite dans le trop grand nombre de pages a gérer qui sont de plus évolutives. Ce qui conduit a privilégier des protocoles entièrement automatisables sous forme d'algorithme.

Dans cet optique, Google a cherché un modèle de hiérarchisation qui soit exploitable dans tous les domaines, utilisable pour tous les mots clés, adaptable a un très grand nombre de données, même évolutives, tout en étant automatisable et suffisamment efficace.

C'est en répondant a ce cahier des charges que ce nouveau venu a réussi l'exploit, en quelques mois et malgré l'émergence de Bing ou encore Qwant, a obtenir le quasi-monopole de la recherche thématique sur le web.

L'idée a la base du modèle de Larry Page et Sergey Brin, fondateurs de Google, revient a attribuer a chaque page un nombre positif entre 0 et 1, appelé score (en anglais "PageRank") de la page, qui caractérisera la pertinence de cette page. Ils proposent alors de déterminer ce score à partir deux règles suivantes :

R1 : Le score attribué a une page doit être d'autant plus élevé que celle-ci est référencée dans une page faisant autorité (dont le score élevé).

R2 : Le score attribué a une page doit être d'autant moins élevé que celle-ci est référencée dans une page contenant un grand nombre de références.

Leur idée : **utiliser un surfeur aléatoire.**

2) Le principe du surfeur aléatoire


Après avoir fait la liste (sans classement) de tous les sites traitant la requête, le surfeur aléatoire en choisit au hasard un. Puis il s'intéresse aux liens hypertexte du site sur lequel il se trouve vers les autres sites qu'il a listé. Il en choisit alors un au hasard et répète cette opération sans s'arrêter en comptant pour chacun des sites combien de fois il l'a visité. Les sites sont alors affichés dans l'ordre décroissant de leur nombre de visites.

Ainsi pour un certain mot clé rentré, il s'intéresse aux sites qui évoquent ce mot-clé mais également aux liens hyper-texte qui permettent de passer d'un site à l'autre.

a) TP n°1 : jeu / étude d'un premier graphe

matériel : un dé à six faces

Pour illustrer comment un algorithme de calcul peut être mis en place à partir de ces règles, nous allons prendre l'exemple du classement de quatre pages. Le problème de l'attribution du score peut être représenté par un graphe orienté : les quatre pages sont représentées par les quatre sommets d'un graphe dont les arêtes orientées représentent les références (liens) pouvant exister entre ces différentes pages.




Dans ce graphe, la flèche allant de 1 vers 2 signifie que la page 1 référence la page 2 et l'absence de flèche de 2 vers 4 signifie que la page 2 ne référence pas la page 4.

- Choisissez un site parmi les 4 qui sera votre point de départ pour tout l'exercice.
- Comment avec un dé pouvez-vous simuler un déplacement aléatoire de notre surfeur ?
- Simuler pendant un certain temps le surfeur aléatoire en n'oubliant pas de noter le nombre de fois où il est passé par site.
- Proposer un classement de ces 4 pages.
- Comparer votre classement avec les autres groupes.
- Est-ce intéressant de comparer vos effectifs avec ceux des autres groupes ? Que peut-on faire pour remédier à ce problème ? Que remarque-t-on alors ?

b) TP n°2 : jeu / étude d'un premier graphe


Estimer le PageRank des sites représentés par le graphe ci-dessous.
Comparer vos scores avec les autres groupes. On effectuera 50 surfs aléatoires.



c) Quelques petits problèmes...

C.1 : Un premier problème

La technique du surfeur aléatoire ne marche pas pour le graphe suivant :



Pourquoi ?


Proposer une solution pour pallier à ce problème.

Faites alors une proposition de classement pour ce graphe après avoir calculé le PageRank.

Comparer vos résultats avec les autres groupes.

C.2 : Puits

Calculer les PageRank du graphe suivant. Comparer le avec les autres groupes.




Quel problème moral est soulevé par ce graphe ?

Avez vous une solution à proposer pour pallier à ce problème ?

C.3 : poche web :

Estimer les PageRank des sites suivants. Comparer avec les autres groupes.



Quel problème est soulevé par ce graphe ?

Avez vous une solution à proposer pour pallier à ce problème ?

3) Modification de l'algorithme

a) Heureusement il y a les maths !

Un théorème complexe d'algèbre linéaire qui peut s'adapter à notre cas : le théorème de Perron-Frobenius nous dit que si de chaque sommet part un lien vers chacun des autres sommets alors les fréquences des positions au cours de notre surf aléatoire vont toujours converger vers la même valeur et cela indépendamment de la position de départ.

b) Idée Brillante de L. Page et S. Brin

Préalable : Si une page ne comporte aucun lien vers l'extérieur, comme le sommet 2 du graphe 3, on crée artificiellement un lien de la page vers toutes les autres pages. *Détail de l'idée* :

- À chaque étape, on continue la promenade aléatoire précédente avec une probabilité de 0.85 ;
- et avec probabilité de 0.15, on fait un saut aléatoire (vers n'importe quelle page) avec une probabilité $1/n$ de tomber sur une page donnée, où n est le nombre de pages.

On peut démontrer mathématiquement que cette façon de procéder permet de faire systématiquement rentrer le graphe considéré dans le champ d'application du théorème de Perron-Frobenius. Cela garantit donc la convergence des fréquences vers des valeurs limites qui seront considérées comme étant les pages-Rank. Leur méthode résout au passage le cas des puits car elle empêche de se retrouver dans une poche du web sans pouvoir en sortir. De plus, plutôt que de calculer les valeurs limites, calculs qui se révèlent dans la pratique très long, l'algorithme du PageRank simule comme l'on vient de le faire un surfeur aléatoire et prend les fréquences trouvées comme estimation des valeurs limites.

c) Prolongement possible :


1. Grâce à la méthode des fondateurs de Google, proposer un classement des pages des quatrième et cinquième graphes.
2. Leur méthode aboutie modifie-t-elle le classement de pages pour lequel il n'y avait pas de problèmes ?

4) A retenir

Le PageRank ou PR est l'algorithme d'analyse des liens concourant au système de classement des pages Web utilisé par le moteur de recherche Google. Il mesure quantitativement la popularité d'une page web.

Le PageRank n'est qu'un indicateur parmi d'autres dans l'algorithme qui permet de classer les pages du Web dans les résultats de recherche de Google.

Ce système a été inventé par Larry Page, cofondateur de Google.



5) Des chaînes de Markov aux « créations artistiques par ordinateur »

*Voir fin de la ressource sur le cours e-lyco
web-activité PageRank02 - au sujet des chaînes de Markov.pdf*

6) Liens avec PIX

T1. Informations et données

1.1 Mener une recherche et une veille d'information

Mener une recherche ou une veille d'information pour répondre à un besoin d'information, se tenir au courant de l'actualité d'un projet (... par abonnement à des flux...)

T2. Communication et collaboration

2.2 Partager et publier

Partager et publier des informations et des contenus pour communiquer ses propres productions ou opinions

2.4 S'insérer dans le monde numérique

Maîtriser les stratégies et enjeux de la présence en ligne, et choisir ses pratiques pour se positionner en tant qu'acteur social, économique et citoyen dans le monde numérique (...)

T3. Création de contenu

3.1 Développer des documents textuels

Produire des documents à contenu majoritairement textuel pour communiquer des idées, rendre compte et valoriser ses travaux (...)

3.2 Développer des documents multimédia

Développer des documents à contenu multimédia pour créer ses propres productions multimédia (...)

3.3 Adapter des documents à leur finalité

Adapter des documents de tous types en fonction de l'usage envisagé (...)

T4. Protection et sécurité

4.1 Sécuriser l'environnement numérique

Sécuriser les équipements, les communications et les données pour se prémunir contre les attaques, pièges, désagréments et incidents susceptibles de nuire au bon fonctionnement des matériels, logiciels, sites internet, et de compromettre les transactions et les données (avec des logiciels de protection, des techniques de chiffrement, la maîtrise de bonnes pratiques, etc.).

4.2 Protéger la vie personnelle et la vie privée

Maîtriser ses traces et gérer les données personnelles pour protéger sa vie privée et celle des autres, et adopter une pratique éclairée (avec le paramétrage des paramètres de confidentialité, la surveillance régulière de ses traces par des alertes ou autres outils, etc.).

Stéphane Percot

Professeur de mathématiques et SNT

Lycée Rosa Parks - La Roche sur Yon (85)

Membre du GRAF SNT - Académie de Nantes