

2 Modelo de Hubs e Authorities

Jon Kleinberg [1,2] propôs um modelo baseado em *hyperlinks* que permitisse a inferência de autoridade e um conjunto de algoritmos que identificasse páginas relevantes para tópicos de busca de caráter geral. Esse modelo é baseado na relação entre páginas que são autoridades sobre um tópico e páginas que interligam essas autoridades (*hubs*). *Jon Kleinberg* observou um equilíbrio natural entre autoridades e *hubs* num grafo definido pela estrutura de *hyperlinks* e desenvolveu um algoritmo, conhecido como *HITS* (*Hyperlink Induced Topic Search*), para identificar, simultaneamente, esses tipos de páginas. O algoritmo opera em um sub-grafo focado da *WWW*, construído a partir do resultado de uma máquina de busca baseada somente em texto.

Apresentamos, a seguir, uma descrição mais detalhada do algoritmo *HITS*.

2.1. Algoritmo *HITS*

A partir de uma consulta de tópico geral especificada pela cadeia σ , é necessário, para se analisar a estrutura de *hyperlinks* e se extrair as páginas que são autoridades, definir qual sub-grafo da *WWW* o algoritmo vai utilizar. Tal sub-grafo (S_σ) deve conjugar três características, quais sejam:

1. Relativamente pequeno;
2. Rico em páginas relevantes;
3. Possuir a maior parte das grandes autoridades;

Para satisfazer às características 1 e 2 supracitadas, basta coletar as t primeiras páginas classificadas por uma máquina de busca baseada somente em texto – empiricamente, são escolhidas em torno de duzentas páginas. Esse grafo inicial (R_σ) geralmente está longe de satisfazer a terceira condição, pois é notório que páginas que são autoridades normalmente não possuem em seu

texto muitas repetições da palavra da consulta. Um exemplo simples consiste na procura de páginas que tratam sobre “*Harvard*”. A página www.harvard.edu, considerada a maior autoridade sobre o assunto, não possui em seu texto repetidas vezes a palavra “*Harvard*”.

Entretanto, R_σ pode ser usado como base para construir o grafo S_σ desejado. Como antes aludido, as páginas autoridades podem não pertencer a R_σ . Porém, considerando que essas podem ser apontadas por pelo menos uma página de R_σ , é razoável inferir que expandindo o conjunto R_σ através dos *hyperlinks* das páginas pertencentes a R_σ , o grafo resultante passe a satisfazer a condição 3 e, por consequência, gere S_σ (figura 1).




Figura 1: Expansão de R_σ .

A expansão de R_σ consiste em acrescentar as páginas que são apontadas por cada página pertencente a R_σ , e também um número d de páginas que apontam para as páginas de R_σ . Os *hyperlinks* de navegação são desconsiderados, formando um grafo orientado apenas com arestas interdomínios. Definindo o sub-grafo com $G=(V,E)$, esse é constituído de uma coleção V de páginas conectadas por seus *hyperlinks*, em que os vértices são as páginas e as arestas orientadas $(p,q) \in E$ são *hyperlinks* de p para q .

A seguir, apresentamos o pseudocódigo da rotina de expansão do sub-grafo:

```

Subgraph( $\sigma, \epsilon, t, d$ )
 $\sigma$ : palavra da consulta
 $\epsilon$ : máquina de busca baseada em texto
 $t$ : tamanho do núcleo inicial

```

d : número de páginas que apontam para as páginas do núcleo
 Seja R_σ o conjunto das t mais significantes páginas retornadas por ϵ com σ
 $S_\sigma := R_\sigma$
 Para cada página $\epsilon \in R_\sigma$
 Seja $A(p)$ o conjunto de todas as páginas que p aponta
 Seja $A^-(p)$ o conjunto de todas as páginas que apontam para p
 Adicione todas as páginas de $A(p)$ em S_σ
 Se $|A^-(p)| < d$ então
 Adicione todas as páginas de $A^-(p)$ em S_σ
 senão
 Adicione um conjunto arbitrário d de páginas de $A^-(p)$ em S_σ
 Retorne S_σ

Após a construção do sub-grafo, o problema converge para a extração e classificação das autoridades existentes, considerando apenas a estrutura de *hyperlinks* existente. Analisando a estrutura, as autoridades relevantes presentes possuem não só um alto grau de *hyperlinks* que as apontam, como também possuem grupos de páginas que as apontam em comum. Essas páginas são denominadas *hubs* e são responsáveis por vincular as autoridades comuns excluindo as páginas que possuem um alto grau de *hyperlinks* de chegada e não são relevantes para o assunto (figura 2).




Figura 2: *Hubs* e autoridades.

Sendo assim, autoridades e *hubs* exibem uma relação de interdependência: uma boa autoridade será uma página apontada por bons *hubs* e um bom *hub* será uma página que aponta para boas autoridades.

Com base nessa relação, um algoritmo iterativo foi desenvolvido permitindo encontrar os *hubs* e as autoridades. Cada página i possui dois pesos não negativos associados, um para autoridade ($a^{<i>$) e um para *hub* ($h^{<i>$). Desta

forma, é natural reescrever a relação de interdependência como: se uma página p aponta para páginas com altos valores de a , então ela deve receber um valor alto para h , e se p é apontada por páginas com valores altos de h , essa deve receber um valor alto para a .

Em face do exposto, dois operadores foram definidos para atualizar os pesos de autoridade (I) e os de *hubs* (O):

$$\begin{aligned}
 - I: a^{<p>} &\leftarrow \sum_{q:(q,p) \in E} h^{<q>} ; \\
 - O: h^{<p>} &\leftarrow \sum_{q:(p,q) \in E} a^{<q>} .
 \end{aligned}$$

Tais operadores representam claramente a relação de interdependência entre *hubs* e autoridades.

Para encontrar o valor de equilíbrio entre os pesos, são aplicados, alternadamente, os operadores I e O até que a estabilidade seja alcançada[1,2], ou seja, que os valores de a e h das páginas se tornem inalterados com a iteração do algoritmo.

A seguir, apresentamos o pseudocódigo do algoritmo de iteração:

```

Iterate(G,k)
( G : coleção de n páginas com hyperlinks )
( k : número de iterações do algoritmo )

Seja z o vetor (1,1,1...1) ∈ Rn
a0 := z
h0 := z
Para i := 1,2..k
  Aplicar I em (ai-1,hi-1), obtendo ai
  Aplicar O em (ai,hi-1), obtendo hi
  Normalizar ai, obtendo ak
  Normalizar hi, obtendo hk
Retornar (ak,hk)

```

Por fim, basta ordenar as coordenadas do vetor a , retornadas pelo algoritmo *iterate*, para expor as páginas de maior autoridade. O mesmo se aplica ao vetor h para as páginas de maior *hub*.