

Ecossistema de Ligações da Blogosfera Portuguesa

José Luís Devezas

Faculdade de Engenharia da Universidade do Porto
Rua Dr. Roberto Frias, s/n
4200-465 Porto, Portugal
joseluisdevezas@gmail.com

22 de Março de 2010

Conteúdos

1 Introdução

- O que é a blogosfera?
- Estudar a blogosfera
- Enunciado de tese

2 Conhecer a amostra

- Colecção
- Tecnologias
- Extração e validação do conjunto de dados

3 Análise de ligações

- Estrutura de dados
- Preparação dos dados
- Total de ligações, por dia, ao longo do tempo
- Agrupamento de blogues
- Número de palavras por entrada, para o grafo simplificado
- Número de palavras por entrada, para o grafo original
- Número de entradas criadas por mês, para o grafo original
- Número mensal de ligações p/entrada, para o grafo original

4 Conclusões

- Principais contribuições
- Trabalho futuro

Introdução

O que é a blogosfera?

Definição

A blogosfera consiste no conjunto de todos os blogues e suas interligações.

A blogosfera é:

- Uma rede de blogues;
- Um conjunto de textos ricos em imagem e vídeo;
- Um conjunto de entradas cronologicamente ordenadas.

O estudo da blogosfera pode focar-se:

- Na evolução da colecção;
- No conteúdo das entradas;
- Nos comentários;
- Na estrutura de ligações.

Através da análise de ligações, identificar e caracterizar conjuntos de blogues, com o objectivo de provar que:

Afirmação

Existe um padrão consistente de variação de características dos blogues com a popularidade.

Conhecer a amostra

- Disponibilizada pelo SAPO;
- Entradas escritas em português;
- Vários domínios, principalmente Blogues do SAPO e Blogger;
- Entradas entre 1 de Março de 2006 e 1 de Outubro de 2009.

- Base de dados relacional MySQL.
- Base de dados chave \Rightarrow valor Berkeley DB.
- Dialecto GraphML para representação de grafos.
- Linguagem e ambiente R para computação estatística e gráficos.
 - ▶ Biblioteca ggplot2 para criação de gráficos.
 - ▶ Biblioteca igraph para manipulação de grafos.
- Linguagem Perl.
 - ▶ Extração e selecção de dados.
 - ▶ Processamento e indexação de conteúdos.
 - ▶ Geração do documento GraphML e tabelas de entrada para o R.

Extracção e validação do conjunto de dados

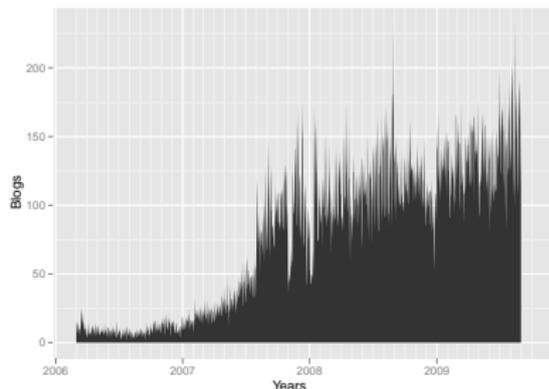
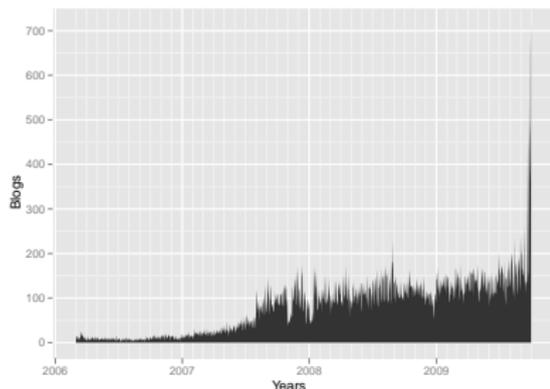
Dos 17 GB de registos são seleccionadas as entradas:

- Cujo domínio contém “blogs.sapo.pt”;
- Datadas entre 1 de Março de 2006 e 30 de Setembro de 2009.

É feita a indexação de cada blogue no formato blogue \Rightarrow entradas:

```
blogue.blogs.sapo.pt =>  
  http://blogue.blogs.sapo.pt/112.html|2008-02-01 23:45:32\t  
  http://blogue.blogs.sapo.pt/342.html|2008-05-13 10:27:13\t  
  http://blogue.blogs.sapo.pt/678.html|2008-11-11 11:13:27
```

Extracção e validação do conjunto de dados



Número de blogues criados por dia ao longo dos anos.

- Contagem do número de blogues e entradas criados por dia.
- Durante o mês de Setembro de 2009 observa-se um pico anormal.
- Uma verificação automática determina que 42% dos blogues desse mês não existem no mês seguinte.
- Setembro de 2009 é removido do estudo.
- Crescimento acentuado após a primeira metade de 2007.

Análise de ligações

Estrutura de dados

- Grafo dirigido para representar a rede de blogues.
 - ▶ Vértices \Leftrightarrow Blogues.
 - ▶ Arestas \Leftrightarrow Ligações entre os blogues.
(provenientes de âncoras, imagens e conteúdo embebido no HTML das entradas)
- Vários atributos associados aos vértices e arestas.

	Atributo	Exemplo
Blogues	name	blog.blogs.sapo.pt
	date	2007-10-11 16:22:57
	hostgraph.outdegree	50.077
Entradas	post.url	http://blog.blogs.sapo.pt/1046448.html
	post.date	2008-09-09 19:14:49
	post.wordcount	25
	post.charcount	216
Ligações	name	http://outro.blogs.sapo.pt/25856.html
	source	blog.blogs.sapo.pt
	target	outro.blogs.sapo.pt

Informação captada no grafo de blogues.

Preparação dos dados

Passar da tabela de entradas, disponível na base de dados, ao grafo de blogues envolve:

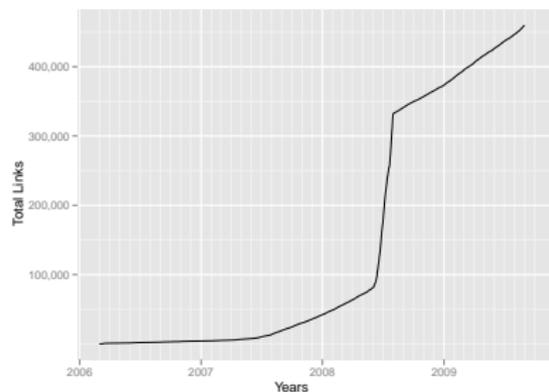
- 1 Extrair e indexar as ligações no formato ligação \Rightarrow entradas

```
http://bit.ly/23a5b =>  
  http://blogue.blogs.sapo.pt/112.html|2008-02-01 23:45:32|50|200\t  
  http://outro.blogs.sapo.pt/1243.html|2008-05-13 10:27:13|19|101\t  
  http://outro.blogs.sapo.pt/1122.html|2009-11-11 11:13:27|7|32
```

- 2 Agregar por domínio, contabilizando as ligações de entrada e de saída;
- 3 Remover domínios externos ao Blogues do SAPO e associar a data de criação a cada blogue;
- 4 Gerar um documento GraphML que represente a rede de blogues;
- 5 Carregar o documento GraphML no R, para ser analisado utilizando a biblioteca `igraph`.

Total de ligações, por dia, ao longo do tempo

- 459.737 ligações, extraídas de 72.591 blogues.
- Taxa média de crescimento mensal: 17,88%.
- Pico de utilização de ligações durante Junho e Julho de 2008.
- Resulta no aumento acentuado do número de ligações.



Agrupamento de blogues

- Blogues ordenados por popularidade.
- Número de citações como critério de classificação.
- Duas versões do grafo de blogues:

Grafo original Uma ilustração crua da realidade da blogosfera \Leftrightarrow quantidade;

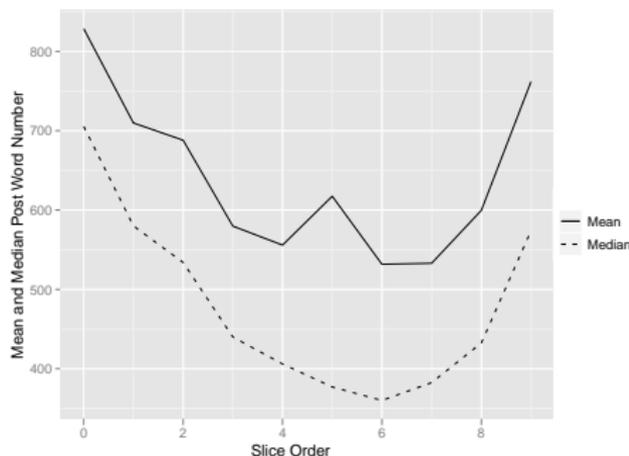
Grafo simplificado Sem multiplicidade de arestas e auto-citações, ignorando nós com menos de duas ligações de entrada ou de saída \Leftrightarrow variedade.

- Grafos de blogues partidos em fatias de 1.000 blogues.
- Análise da evolução do valor médio e mediano de várias características, para fatias progressivamente menos populares.

Número de palavras por entrada, para o grafo simplificado

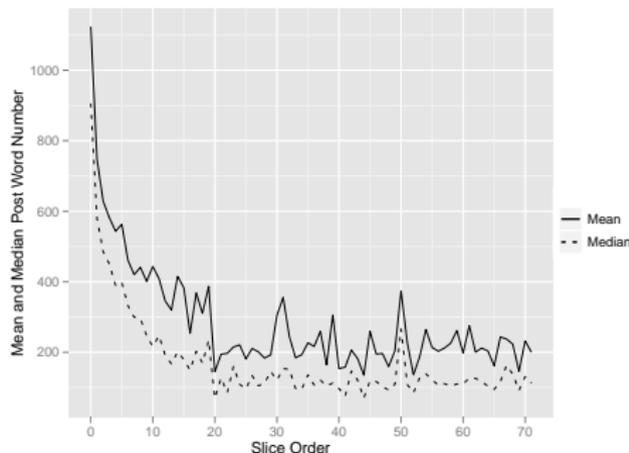
- Eixo dos XX: ordem da fatia — a fatia 0 representa o conjunto dos 1.000 blogues mais citados e a fatia 9 representa os 1.000 blogues menos citados.
- Eixo dos YY: média ou mediana do número de palavras por entrada nos blogues da fatia.

Ordem	Média	Mediana
0	829	706
6	532	360
9	762	574



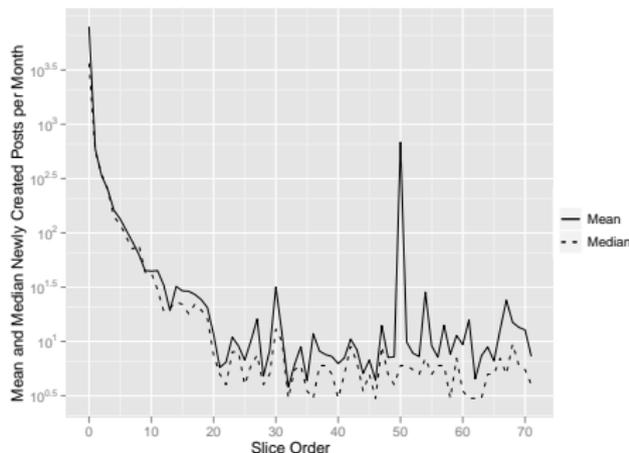
Número de palavras por entrada, para o grafo original

- Blogues mais citados: média de 1.124 palavras por entrada.
- Blogues restantes: média entre 135 e 749 palavras.
- Decréscimo constante, mas não muito acentuado.



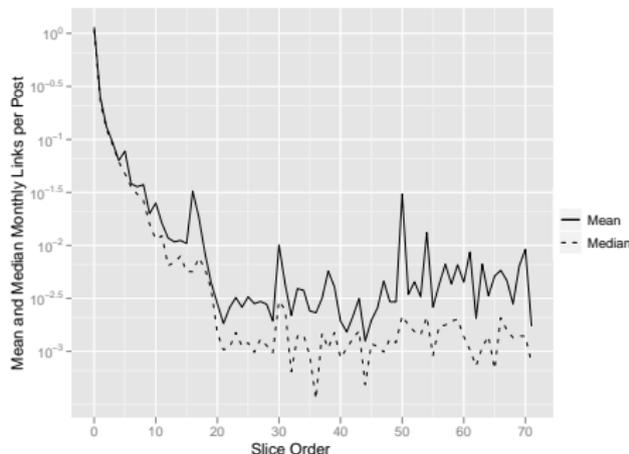
Número de entradas criadas por mês, para o grafo original

- Blogues mais citados: média de 7.934 novas entradas por mês.
- Outras blogues mais citados: média superior a 100 — 594 para a segunda fatia mais citada.
- Blogues menos citados: média entre 5 e 30 novas entradas mensais.



Número mensal de ligações p/entrada, para o grafo original

- Blogues mais citados são os que ligam mais a outros blogues.
- No entanto, em geral, as entradas não contêm um grande número de ligações.
- A fatia mais citada tem em média 1,15 ligações por entrada.
- As restantes fatias têm uma média inferior a 0,25 ligações por entrada.
- Na fatia menos citada é utilizada apenas 1 ligação por cada 1.000 entradas!



Conclusões

Principais contribuições

- Agrupamos blogues utilizando como critério de popularidade o número de citações.
- Blogues populares têm um comportamento distinto dos blogues menos populares.
- Conforme passamos dos blogues mais populares para os menos populares, observámos um padrão de decréscimo:
 - ▶ Na frequência de criação de entradas;
 - ▶ No número de ligações de saída;
 - ▶ No tamanho das entradas.
- Conclui-se que existem efectivamente grupos de blogues com características distintas.

- Estudar a evolução da popularidade dos blogues.
 - ▶ O que influencia um blogue a tornar-se popular.
 - ▶ Como evolui a classificação dos blogues mais populares.
 - ▶ Como evoluem as suas características.
- Estudar as comunidades portuguesas de blogues.
 - ▶ Analisar algoritmos de detecção de comunidades.
 - ▶ Identificar o factor de união dos elementos das comunidades.
 - ▶ Identificar os blogues centrais de cada comunidade.

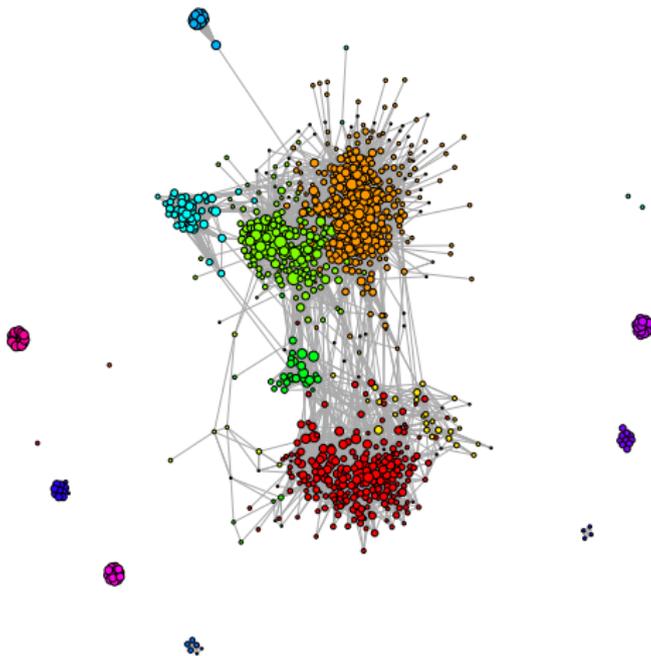
Questões?

Apêndice

Metáfora de ecossistema

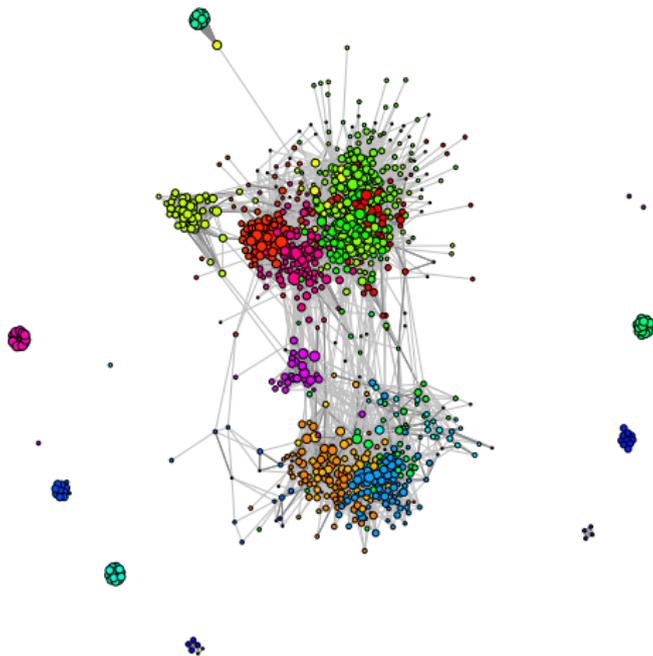
A blogosfera pode ser vista como um ecossistema em que os blogues são considerados organismos que interagem entre si, interligando-se por meio de hiperligações, no ambiente da *World Wide Web*.

Apêndice B.1



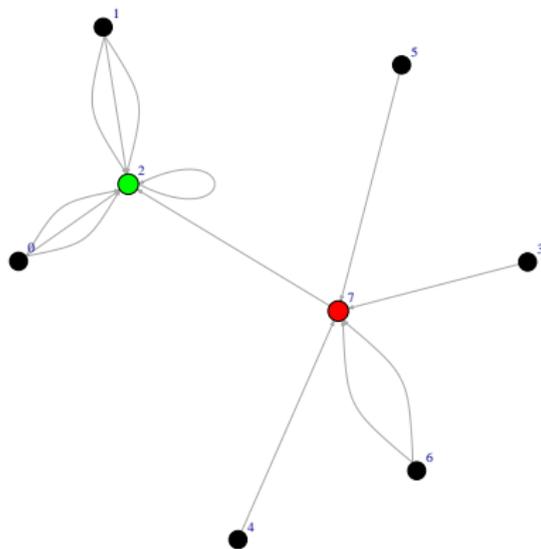
Detecção de comunidades utilizando o algoritmo *Walktrap*.

Apêndice B.2



Detecção de comunidades utilizando o algoritmo *Leading Eigenvector*.

Apêndice C.1

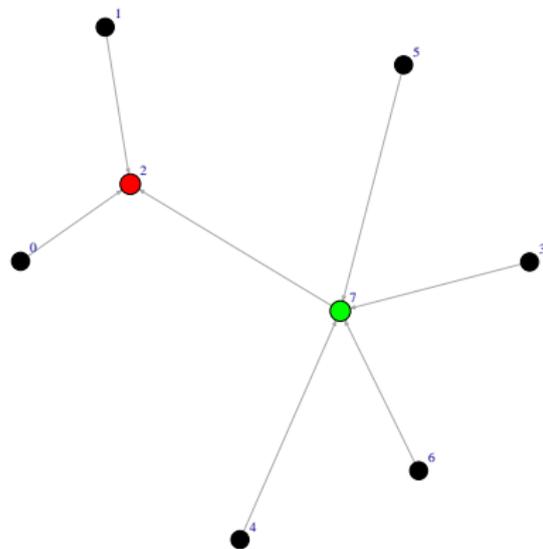


Amostra do grafo de blogues antes da simplificação.

Classificação

Nesta amostra, o nó 2 é citado 8 vezes e o nó 7 é citado 5 vezes. O nó 2 é considerado o mais popular devido à quantidade de ligações que apontam para ele.

Apêndice C.2

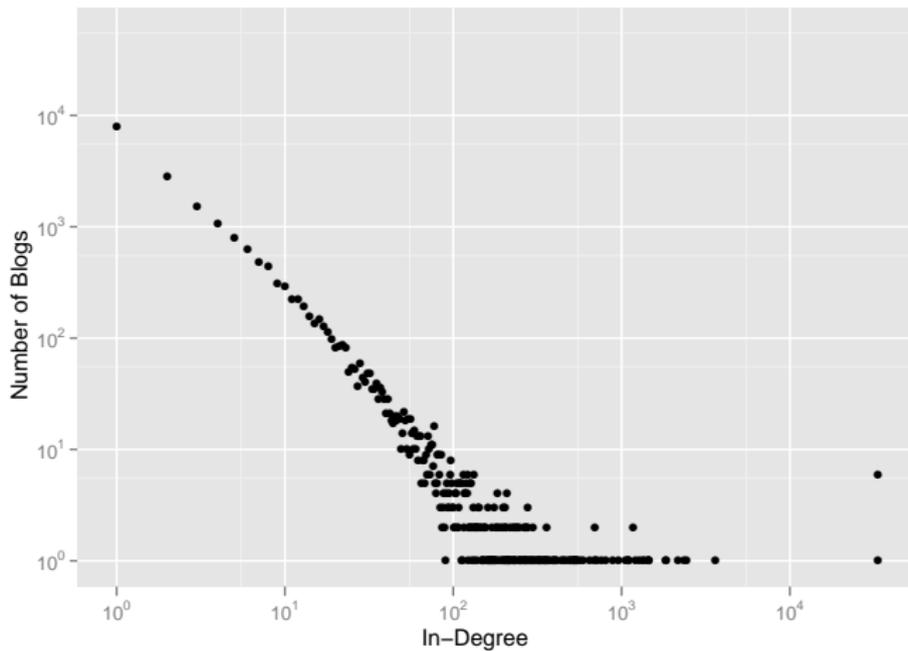


Amostra do grafo de blogues após a simplificação.

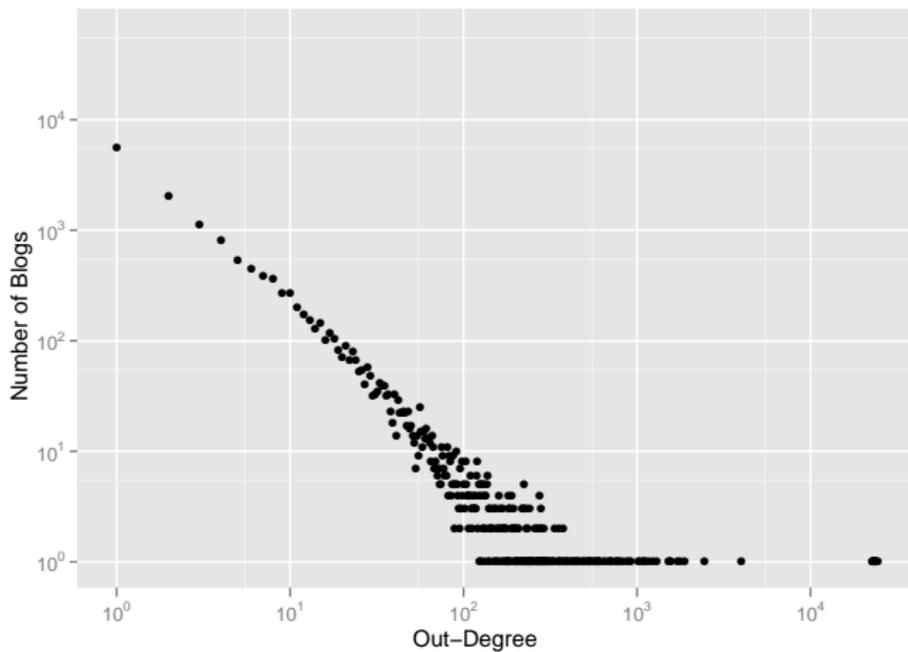
Classificação

Nesta amostra, o nó 2 é citado 3 vezes e o nó 7 é citado 4 vezes. O nó 7 é considerado o mais popular devido à variedade de ligações que apontam para ele.

Apêndice D.1



Apêndice D.2



Distribuição do grau de saída do grafo de blogues.

Apêndice E.1

	Grafo original	Grafo simplificado
Vértices	72.591	10.937
Arestas	459.737	48.399
Densidade	8,72e-5	4,05e-4
Reciprocidade	0,31	0,15
Diâmetro	20	19
Ligações por blogue (média)	6,33	4,43
Ligações por blogue (mediana)	0	2

Apêndice F.1

- Estudar o comportamento dos blogues dependendo da popularidade permite:
 - ▶ Desenvolver estratégias de mercado para publicitar blogues profissionais;
 - ▶ Melhorar o serviço de blogues, adaptando-o aos utilizadores mais activos.
- Estudar as comunidades de blogues permite:
 - ▶ Localizar um blogue na sua comunidade;
 - ▶ Fornecer ao autor do blogue a sua vizinhança;
 - ▶ Determinar os blogues mais centrais de cada comunidade.

Apêndice G.1

- The Most Important Blogging Analysis Ever:
 - ▶ <http://www.viperchill.com/important-blogging-analysis/>
- The Secret to Building a Popular Blog (and Getting Tons of Readers):
 - ▶ <http://www.doshdosh.com/the-secret-to-building-a-popular-blog/>
- Why is Link Popularity Important?
 - ▶ http://blogs.siliconindia.com/uniquestofts2010/Why_is_Link_Popularity_Important-bid-gJ1zb05l46050252.html