Busca, Recuperação e Mineração na Web

Carlos Bazilio

Depto de Computação
Instituto de Ciência e Tecnologia
Universidade Federal Fluminense

Estrutura do Grafo Web

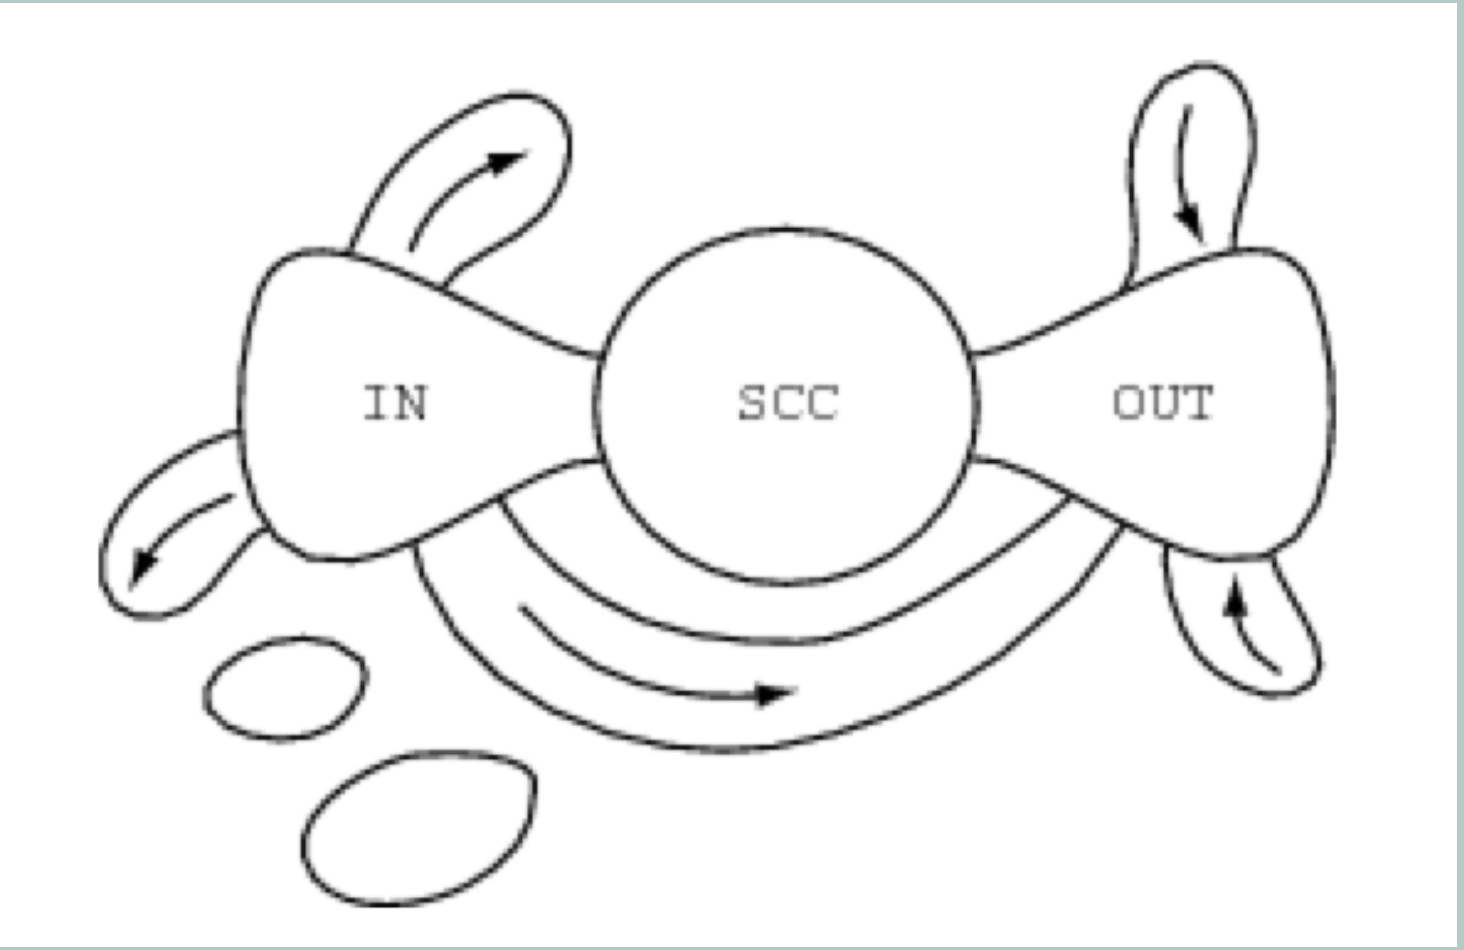

https://www.cs.cornell.edu/home/kleinber/networks-book/ (Cap. 13)

Arquitetura Típica de um Crawler

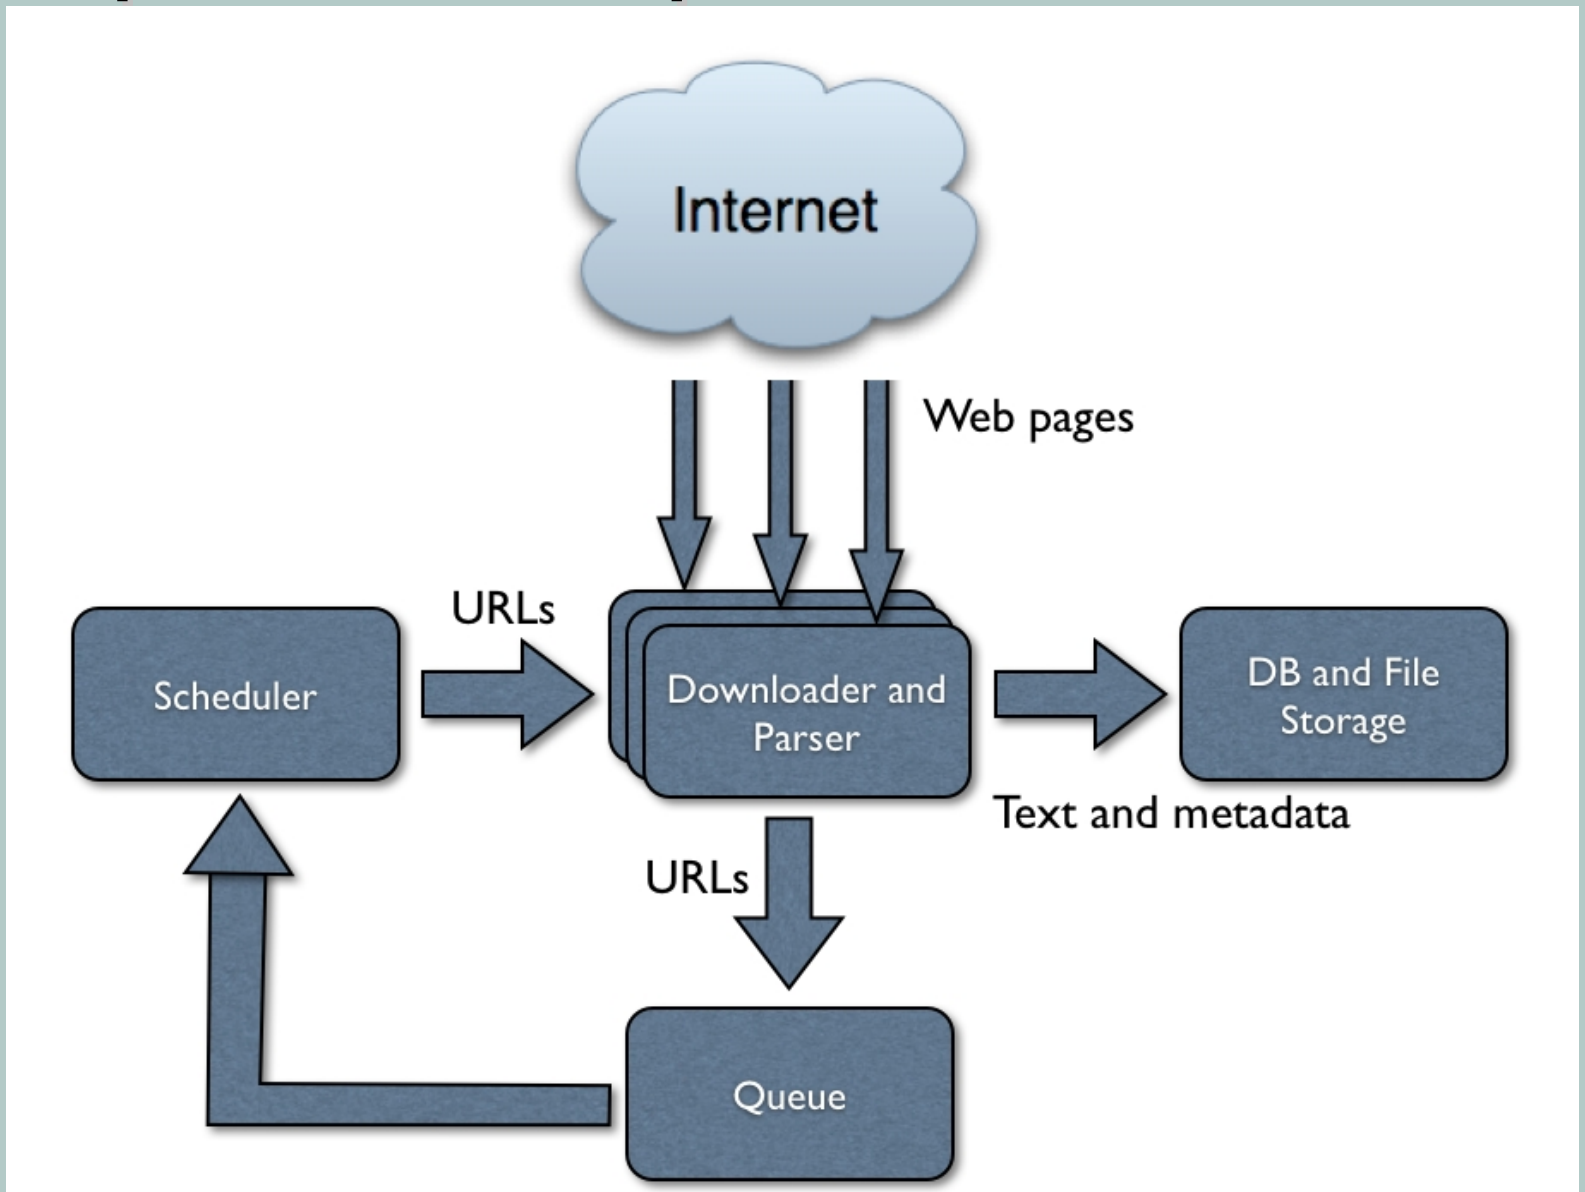

Arquitetura Típica de uma Engine de Busca [1]

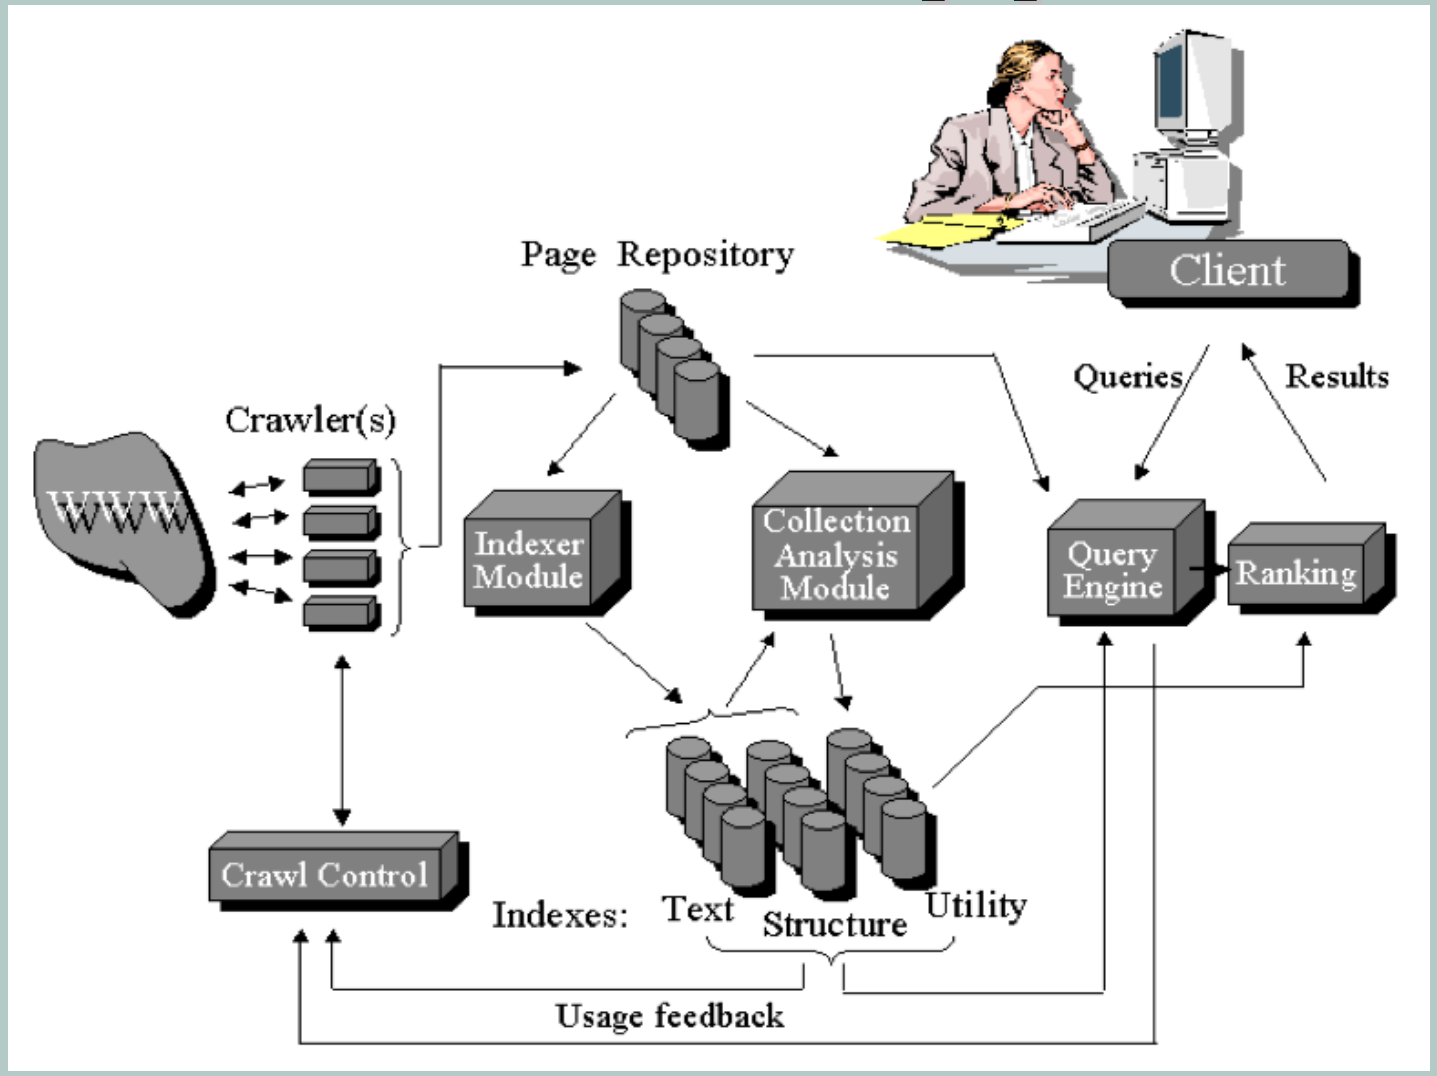

Arquitetura baseada em Cluster para Busca

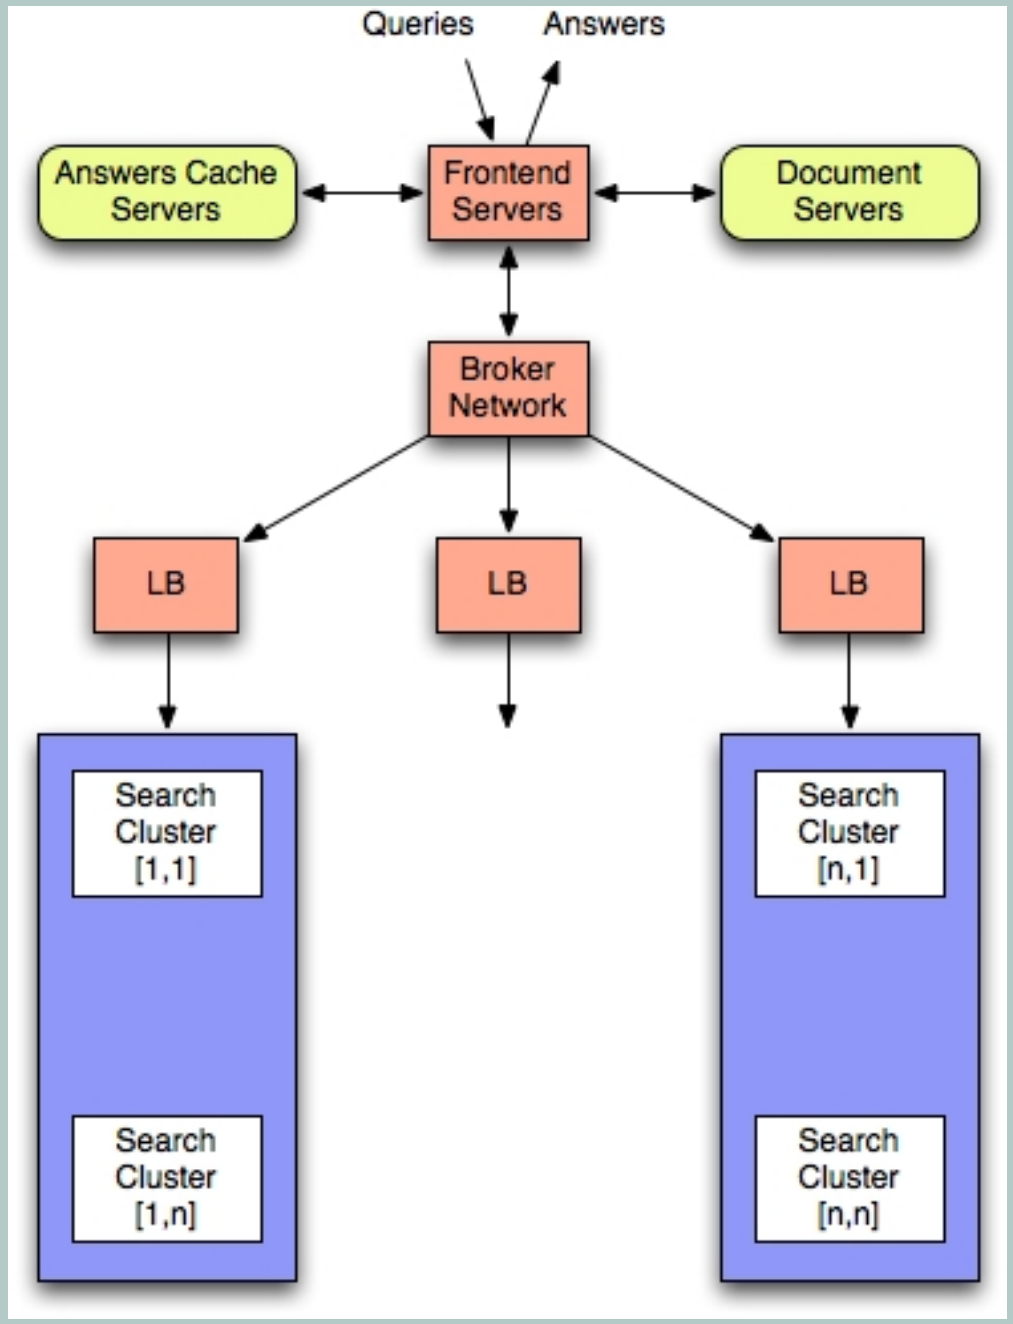

Consultando um Servidor Web

- Conexão a um servidor web utilizando o aplicativo *curl*
- Num prompt, digite o comando abaixo:

> *curl <url>*

Uma Taxonomia para Crawlers

- Questões a se considerar no projeto/implementação de um crawler
  - Atualização das páginas: páginas mais atualizadas possível x páginas “estáticas”
  - Qualidade: poucas páginas com muita qualidade x muitas páginas com diferentes níveis de qualidade
  - Quantidade: muitas páginas x maior atualização e/ou qualidade

O que é Web Mining?

- Web Mining = Web + Data Mining
  - Information Retrieval, Machine Learning, Statistic, Pattern Recognition

Purpose \ Data/information sources	Any data	Textual data	Web-related data
Retrieving known data or documents efficiently and effectively	Data Retrieval	Information Retrieval	Web Retrieval
Finding new patterns or knowledge previously unknown	Data Mining	Text Mining	Web Mining

O que é Web Mining?

- Fontes para Mineração na Web:
  - Conteúdo: textos, mídias, …
  - Estrutura: links, âncoras, …
  - Uso: navegação (“wisdom of crowds”)

Web Mining – Fontes

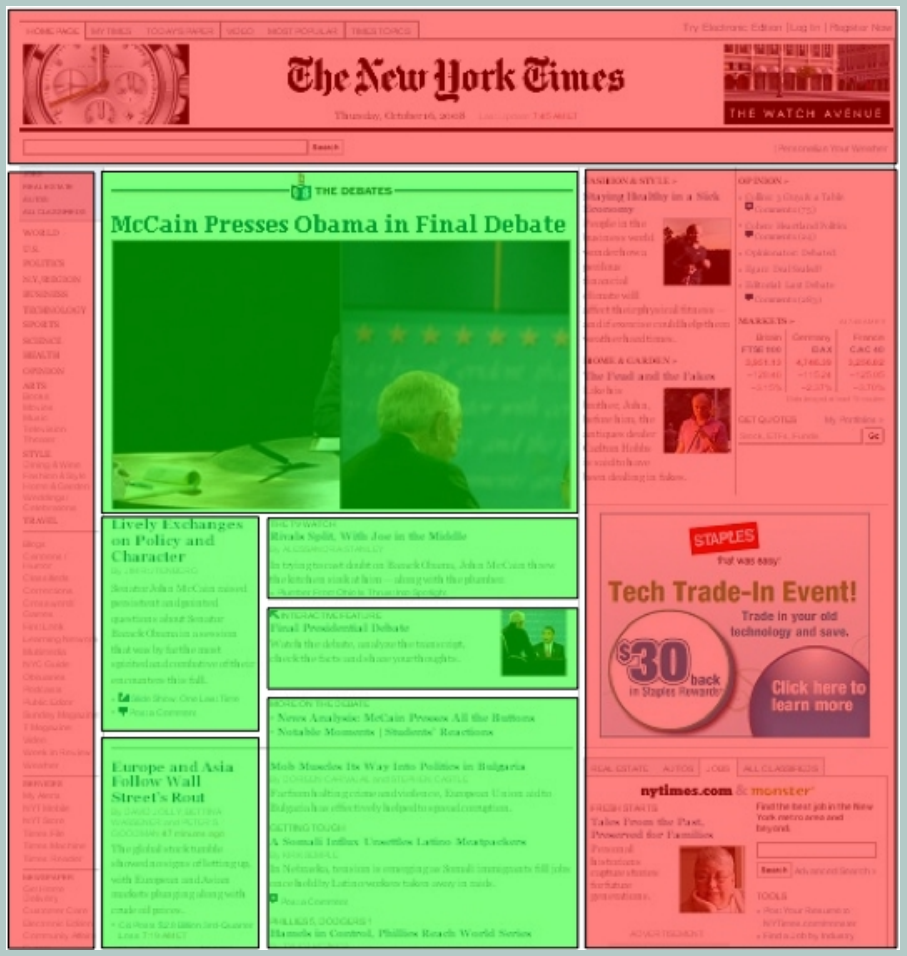

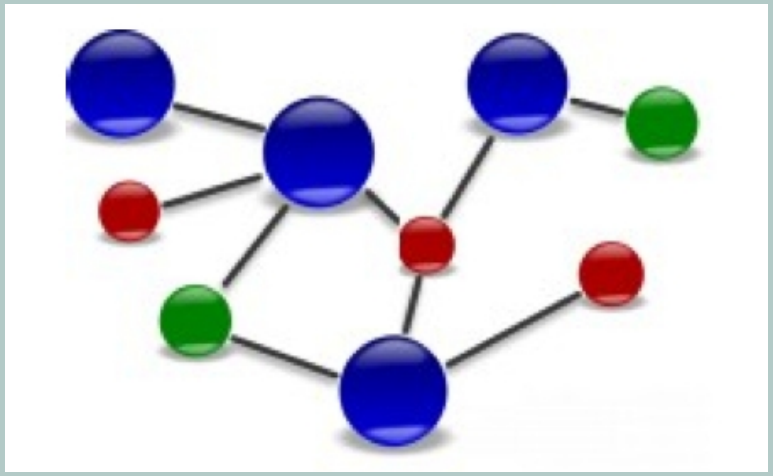

Exemplos de Aplicações

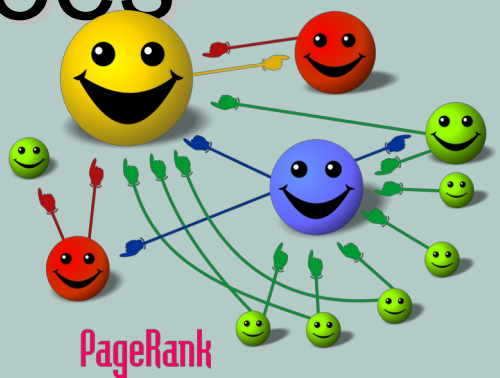

- PageRank

  (Algoritmo de “ranqueamento”)
  - Mineração na estrutura das páginas
  - Uma página tem um bom pagerank se apontam para ela muitas outras
  - Este valor aumenta se as páginas que apontam possuem um bom valor

Exemplos de Aplicações

- Google AdWords (Propaganda)
  - Mineração nas queries / conteúdo
  - Exibe conteúdo relacionado aos termos pesquisados
- Google Analytics
  - Mineração no conteúdo e navegação
  - Registra informações estatísticas de acesso e permanência num site

Exemplos de Aplicações

- Internet Archive (crawler de amplitude global) - http://archive.org
  - Projeto iniciado para armazenamento de versões de imagens de páginas web
  - Exemplos de uso: “www.nytimes.com” em 11/09/2001”, “www.cade.com.br”

Exemplos de Aplicações

- WolframAlpha (Engine para Consulta de Informações - http://www.wolframalpha.com
  - Utiliza uma base de conhecimento para resposta às consultas
  - No site não descreve se há mineração para busca de informações adicionais
  - Exemplo de busca: “16h President of Brazil”, “Hebe Camargo birthdate”

Exemplos de Aplicações

- Netflix (Mineração no Uso)
  - Netflix Prize (http://en.wikipedia.org/wiki/Netflix_Prize)
  - Algoritmos para Recomendação baseado em Visualização
  - Entrevista com funcionários da Netflix: http://www.wired.com/underwire/2013/08/qq_netflix-algorithm/

Exemplos de Aplicações

- NSA (Mineração ???)
  - U.S. National Security Agency
  - Imagens seguintes extraídas do site archive.org

Exemplos de Aplicações

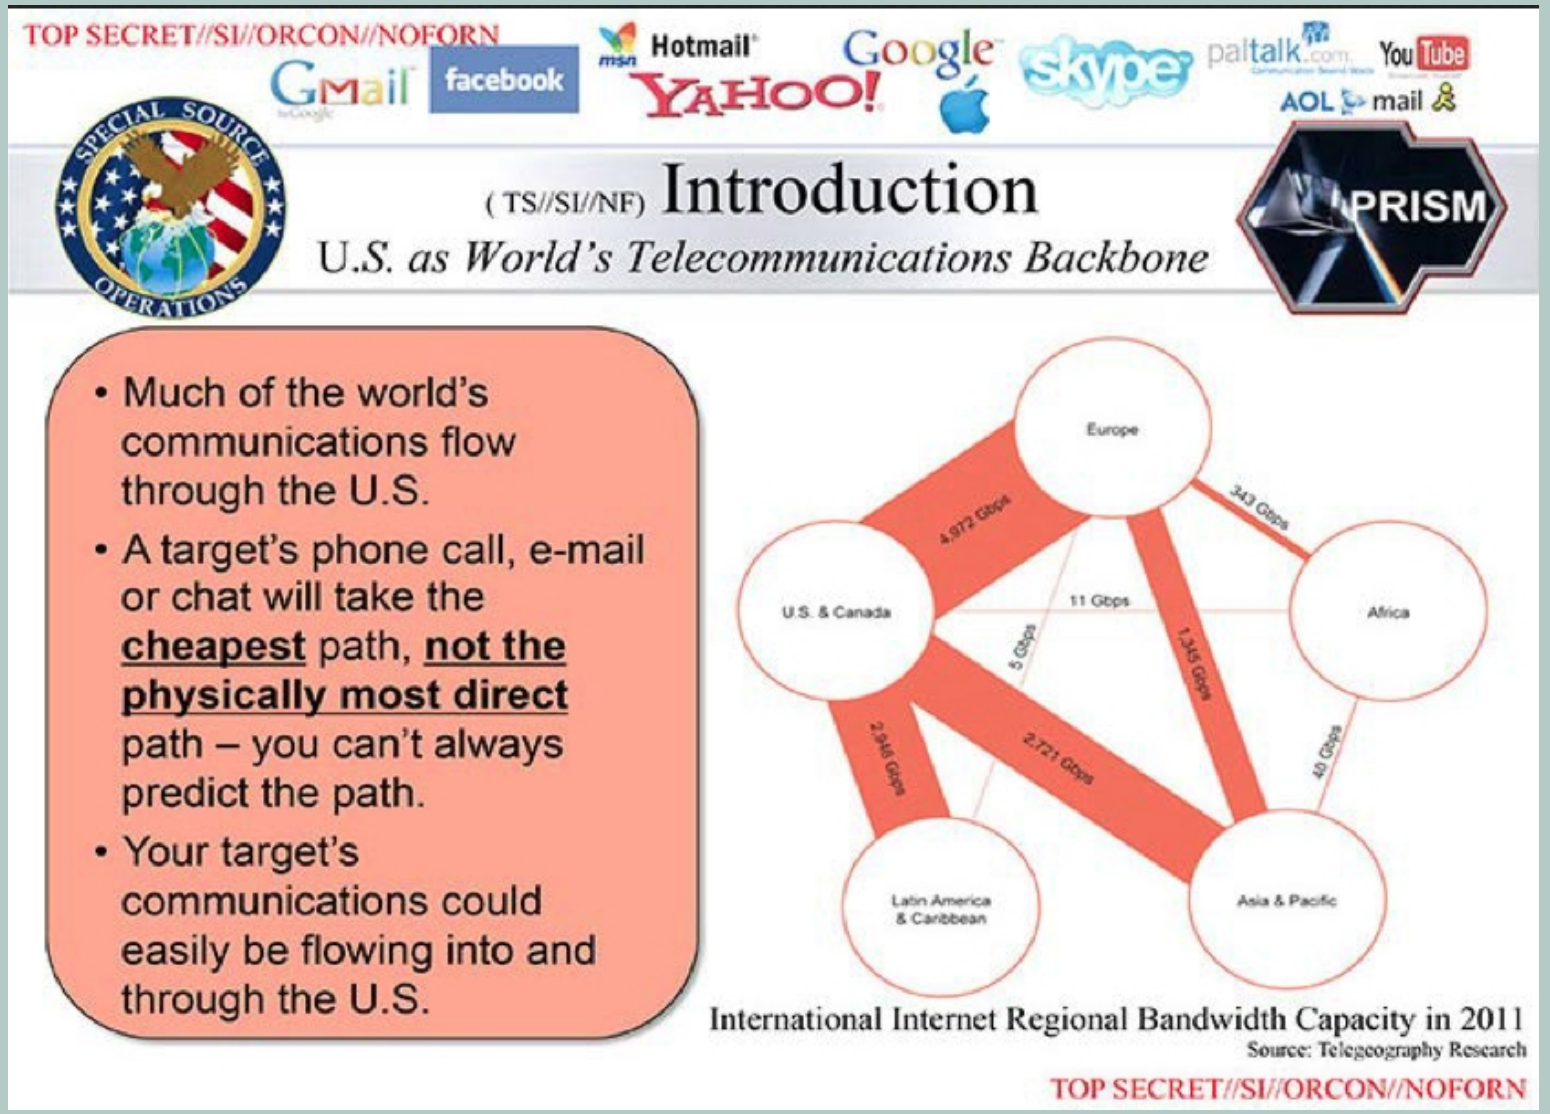

Exemplos de Aplicações

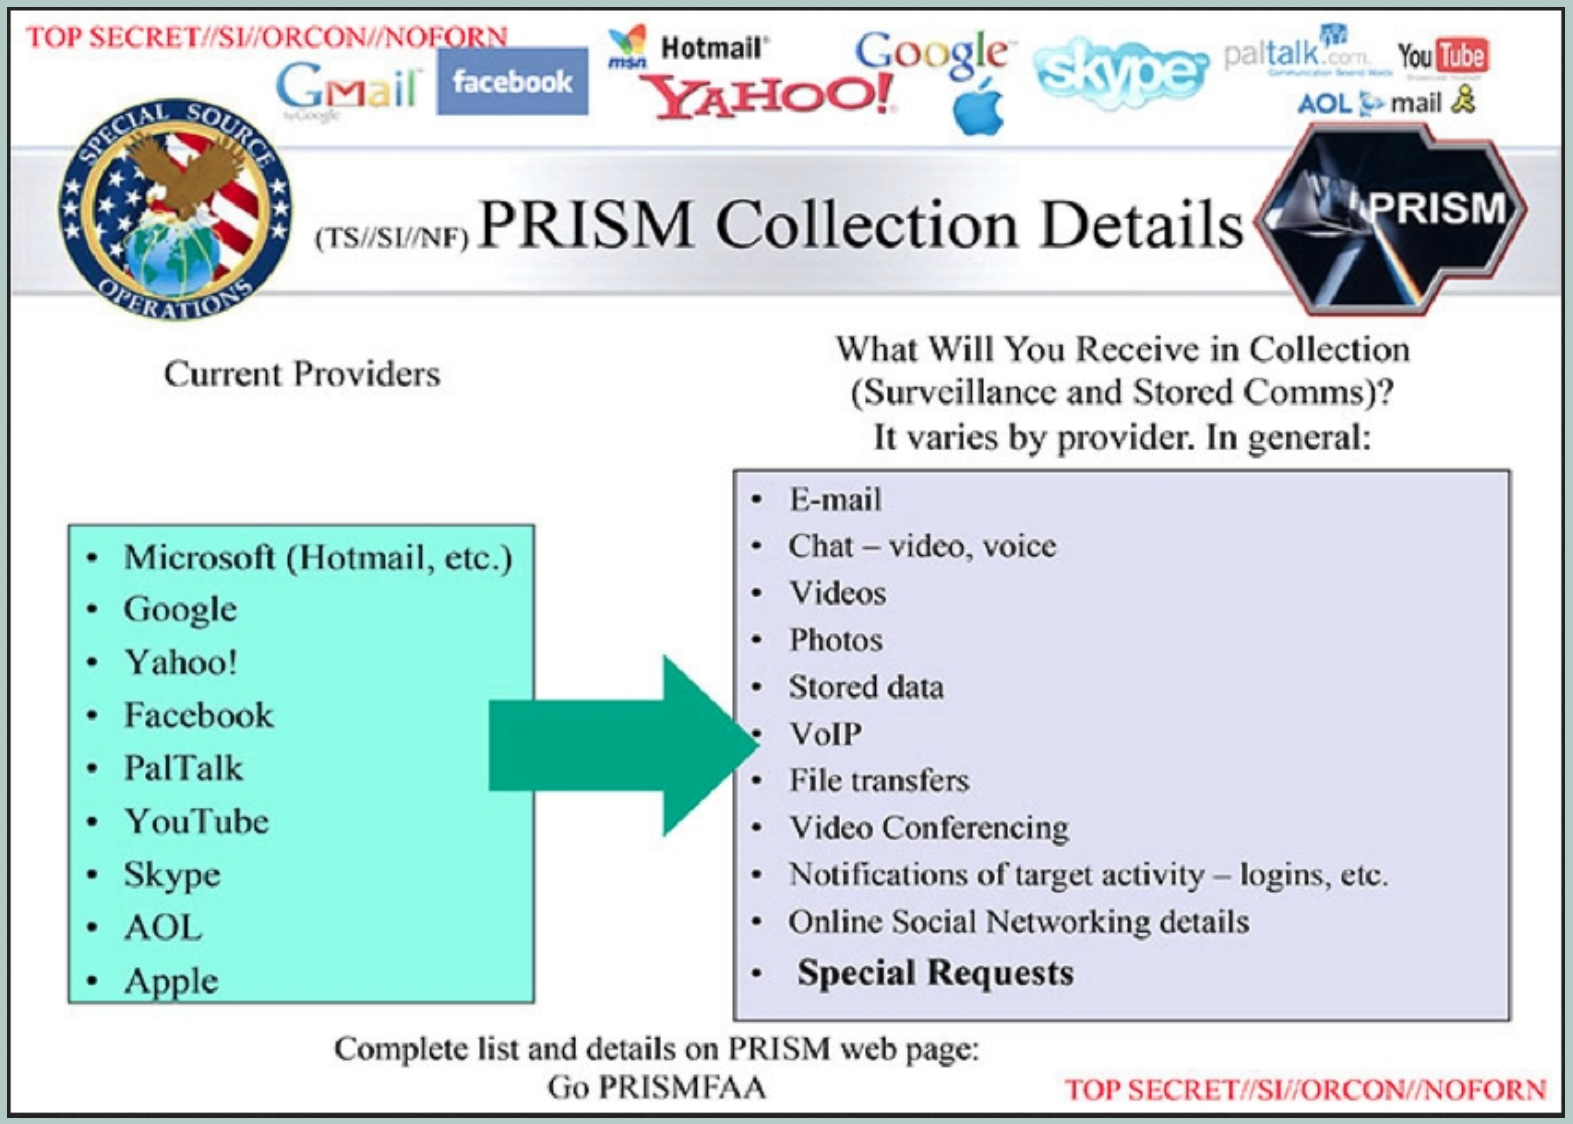

Exemplos de Aplicações

- Google Knowledge Graph
- Facebook Open Graph
- IBM Watson

Desafios na Análise de Dados na Web

- Dados distribuídos
- Dados voláteis
- Grande volume de dados
- Dados não estruturados e redundantes
- Qualidade dos dados
- Formatos heterogêneos
- Como expressar consultas
- Como interpretar os resultados

Referências

[1] *Searching the Web*, Arvind Arasu et. al, Journal ACM Transactions on Internet Technology

[2] Web Mining Research Survey, https://arxiv.org/pdf/cs/0011033.pdf

[3] Web Mining: Examples and Applications, Arne Pottharst