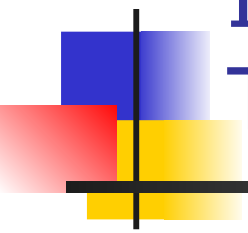

IT4853
Tìm kiếm và trình diễn thông tin

Bài 15. Vấn đề tìm kiếm trên Web

IIR.C19. Web search basics

Bộ môn Hệ thống thông tin
Viện CNTT & TT

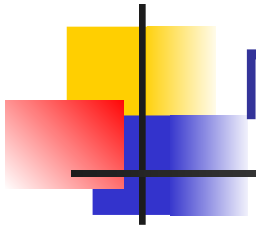

Nội dung chính

- Dữ liệu Web
- Ước lượng kích thước chỉ mục
- Căn bản tìm kiếm trên Web

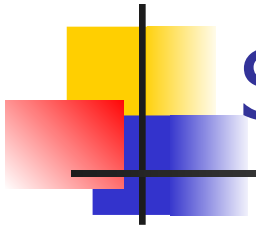

Sao lưu dữ liệu Web

- http://www.archive.org
  - Được ví như "cỗ máy thời gian" với khả năng hiển thị trang web như trong quá khứ
  - Thu gom bởi Alexa và Compaq
  - Năm 2001 quy mô 4 tỉ trang (40 TB)
  - Năm 2002: 100TB

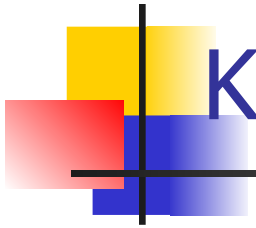

Khó khăn đối với tìm kiếm trên Web

- Phân tán;
- Thay đổi thường xuyên;
- Rất lớn;
- Phi cấu trúc;
- Nhiều trùng lặp;
- Chất lượng không đồng nhất;
- Đa ngôn ngữ.

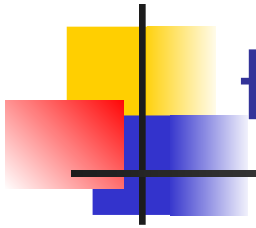

Đặc điểm đồ thị Web

- Coi mỗi trang web (được xác định bởi một url duy nhất) là một đỉnh của độ thị, các siêu liên kết là các cạnh có hướng của đồ thị.
- Broder et al (2000), WWW9
  - Công trình nghiên cứu tính chất đồ thị web quy mô lớn
- Dữ liệu được thu thập hai lần từ AltaVista
  - Tháng 5 năm 99: 203M trang, 1.5 tỉ liên kết;
  - Tháng 10 năm 99: 271M trang, 2.1 tỉ liên kết.

Những khái niệm cơ bản của đồ thị

- Bậc-vào của một đỉnh là số cạnh đi tới đỉnh đó
- Bậc-ra: số cạnh đi ra từ đỉnh
- Đường kính của đồ thị:
  - Giá trị cực đại của các độ dài ngắn nhất giữa tất cả cặp đỉnh (u, v).
- Thành phần liên thông:
  - Thành phần liên thông yếu (WCC – Weakly connected component) là tập đỉnh trong đồ thị vô hướng, trong đó luôn tồn tại đường đi giữa hai nút bất kỳ;
  - Thành phần liên thông mạnh (SCC – Strongly connected component) là thành phần liên thông trong đồ thị có hướng.

Kết quả nghiên cứu

- Broder et al (2000), WWW9
- Số lượng trang với bậc vào i $\propto 1/i^{2.1}$
  - Thống nhất với những nghiên cứu trên quy mô nhỏ hơn
- Kích thước của thành phần liên kết cũng tuân theo quy luật lũy thừa
  - WCC lớn nhất 91%, SCC lớn nhất 26%

Kết quả nghiên cứu (2)

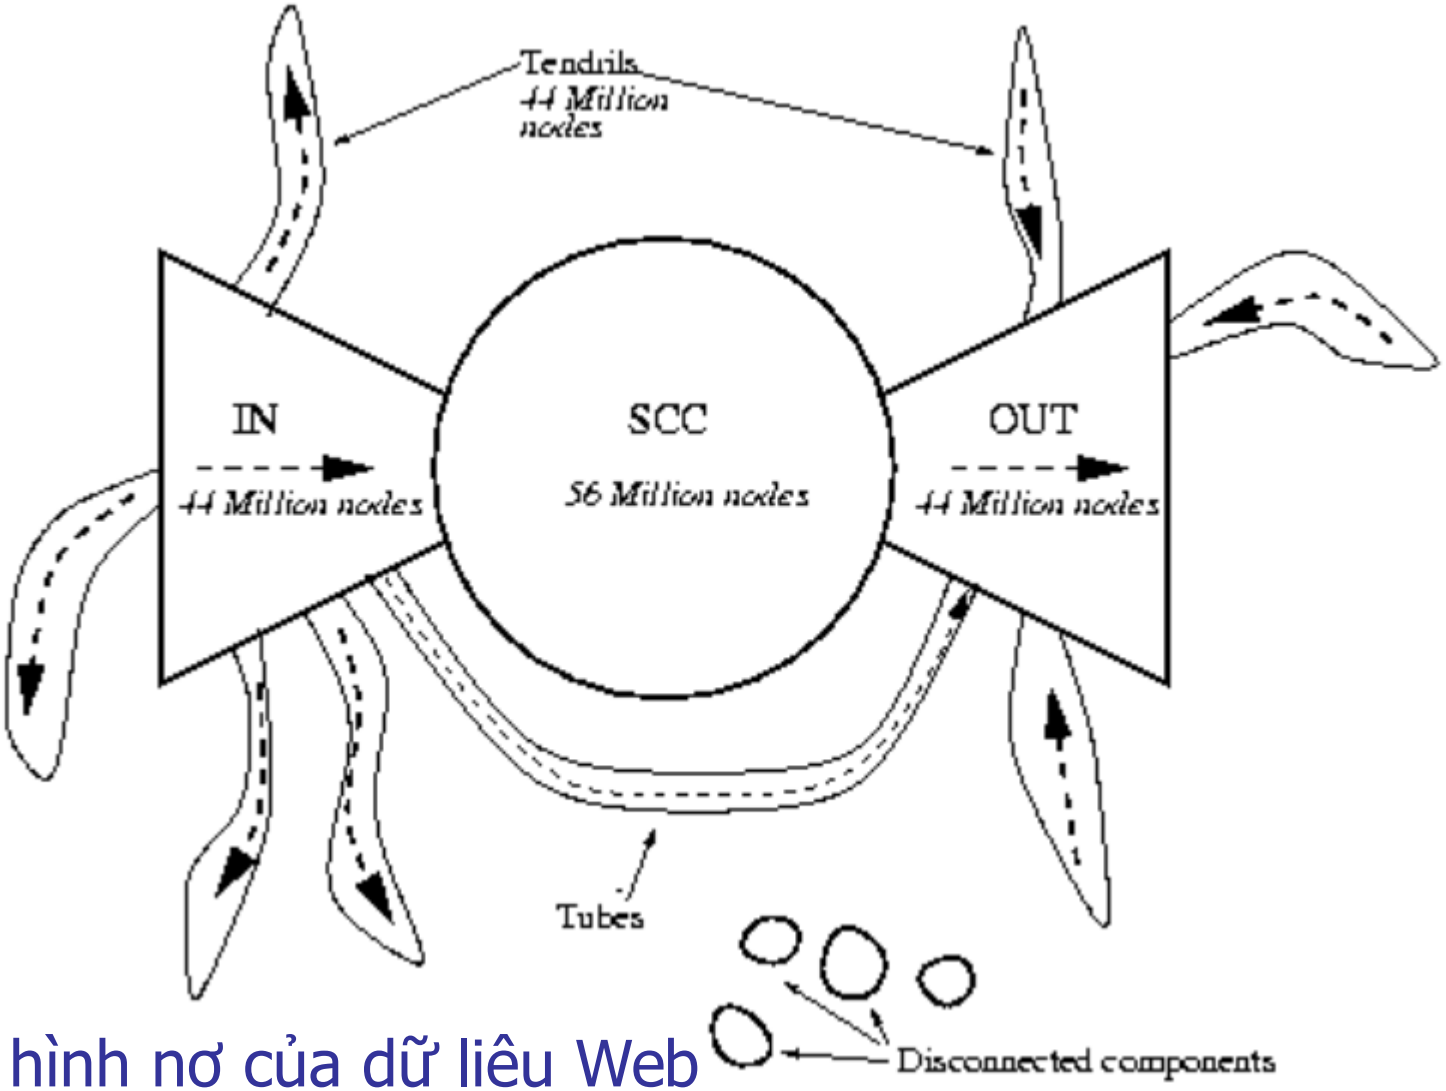

Cấu trúc hình nơ của dữ liệu Web

Kết quả nghiên cứu (3)

- Đường kính tối thiểu của SCC là 28
  - Đường kính của toàn bộ Web là trên 500
- Không phải tất cả cặp đỉnh đều liên thông
  - Cho cặp (u, v) ngẫu nhiên, P(path(u, v))=0,24
    - Xác suất tồn tại đường đi từ u đến v là 0,24
  - Độ dài trung bình của đường dẫn có hướng là 16
    - Đường dẫn vô hướng là 6
- Tuy nhiên trong trường hợp tổng quát, Web có mức liên thông cao
  - Nếu loại bỏ đỉnh với bậc vào > 5, trên Web vẫn tồn tại thành phần liên thông yếu ~ 59M nút

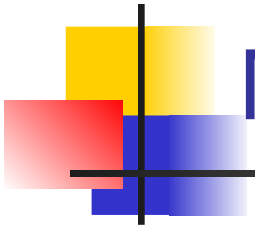

Nội dung chính

- Dữ liệu Web
- Ước lượng kích thước chỉ mục
- Căn bản tìm kiếm trên Web

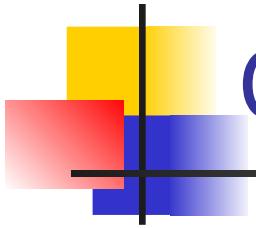

Quy mô dữ liệu web

- Dữ liệu web có thể coi là vô hạn
  - Nội dung động
  - Soft 404: www.yahoo.com/<anything>
- Web tĩnh chứa nhiều trùng lặp (~30%)

Kích thước chỉ mục của công cụ tìm kiếm

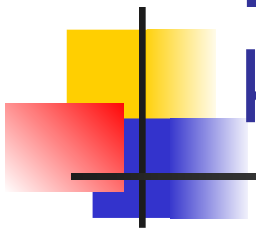

- Công cụ tìm kiếm đánh chỉ mục web tĩnh và web động;
- Các công cụ tìm kiếm khác nhau có dữ liệu chỉ mục khác nhau:
  - Độ sâu url, luật phát hiện spam, độ ưu tiên v.v.
- … thu thập các nội dung khác nhau từ một URL

Tỉ lệ chỉ mục

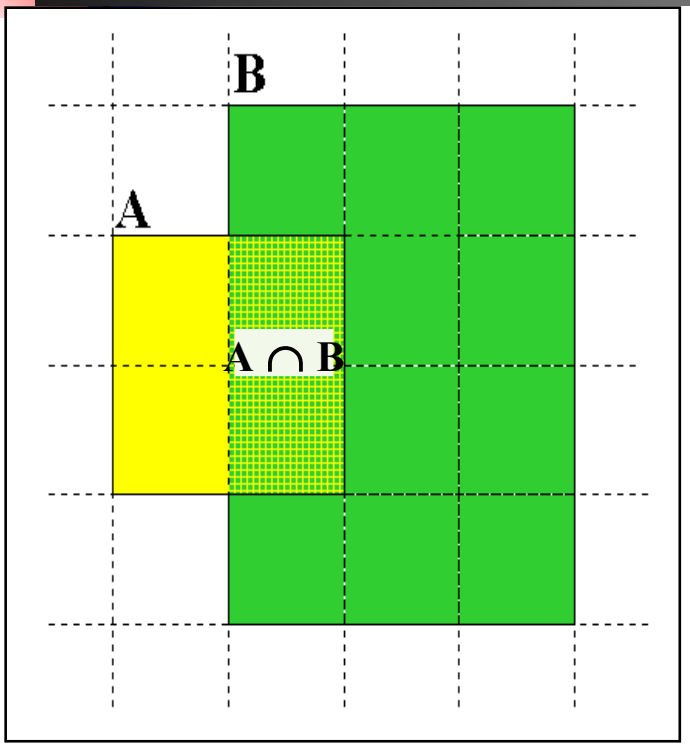

Lấy mẫu ngẫu nhiên URLs từ A, **kiểm tra** nếu có trong B;

và ngược lại

$$A \cap B = (1/2) * \text{Size } A$$

$$A \cap B = (1/6) * \text{Size } B$$

$$(1/2)*\text{Size } A = (1/6)*\text{Size } B$$

$$\therefore \text{ Size } A / \text{ Size } B = (1/6)/(1/2) = 1/3$$

Phép thử: (i) Lấy mẫu (ii) Kiểm tra

Lấy mẫu URLs

- Mục tiêu: Sinh ngẫu nhiên URL và kiểm tra tồn tại trong chỉ mục.
  - Khó xây dựng giải thuật sinh ngẫu nhiên URL trong toàn bộ Web.
  - Có thể sinh ngẫu nhiên URL có trong chỉ mục của công cụ tìm kiếm.
- Giải pháp 1: Sinh ngẫu nhiên URL trong chỉ mục của công cụ tìm kiếm.
  - Xác định tỉ lệ chỉ mục
- Giải pháp 2: Random walks / địa chỉ IP
  - Trên lý thuyết có thể ước lượng kích thước Web.

Ước lượng kích thước của Web [Lawr98, Bhar98a]

- Giả sử các công cụ tìm kiếm đánh chỉ mục một tập con ngẫu nhiên của Web

Nếu E2 chứa x% của E1, thì E2 cũng chứa x% của Web

Biết kích thước E2
Kích thước Web = 100*E2/x

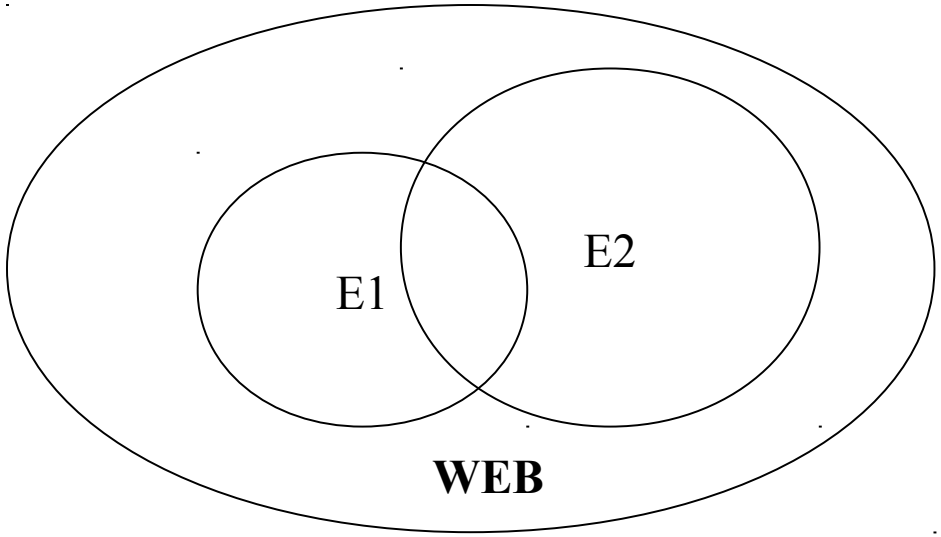

Bharat & Broder: 200 M (Nov 97), 275 M (Mar 98)
Lawrence & Giles: 320 M (Dec 97)

Các truy vấn trong nghiên cứu của Lawrence và Giles

- *adaptive access control*
- *neighborhood preservation topographic*
- *hamiltonian structures*
- *right linear grammar*
- *pulse width modulation neural*
- *unbalanced prior probabilities*
- *ranked assignment method*
- *internet explorer favourites importing*
- *karvel thornber*
- *zili liu*
- *softmax activation function*
- *bose multidimensional system theory*
- *gamma mlp*
- *dvi2pdf*
- *john oliensis*
- *rieke spikes exploring neural*
- *video watermarking*
- *counterpropagation network*
- *fat shattering dimension*
- *abelson amorphous computing*

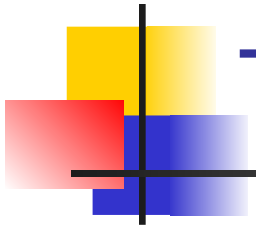

Tỉ lệ đánh chỉ mục Web

- Lawrence and Giles (1998) xác định cận dưới đối với Web: 320M trang có thể đánh chỉ mục.
- Công cụ tìm kiếm chỉ phủ một phần nhỏ của Web:
  - HotBot phủ 34%,
  - AltaVista, 28%
  - Northern Light, 20%
  - Excite, 14%
  - Infoseek, 10%
  - Lycos, 3%

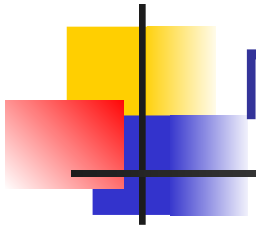

Nội dung chính

- Dữ liệu Web
- Ước lượng kích thước chỉ mục
- Căn bản tìm kiếm trên Web

Vai trò của công cụ tìm kiếm web

- Là động lực thúc đẩy người dùng công bố nội dung trên web
  - Có nên công bố thông tin nếu không ai đọc nó?
  - Có nên công bố nội dung nếu không thu được lợi nhuận?
  - Tìm kiếm giải quyết vấn đề kinh phí vận hành web
  - Máy chủ, thiết bị mạng, việc biên soạn nội dung v.v.
  - Ngày nay phần lớn chi phí được trả nhờ quảng cáo trong tìm kiếm;

Tìm kiếm là hoạt động thường xuyên nhất trên Web

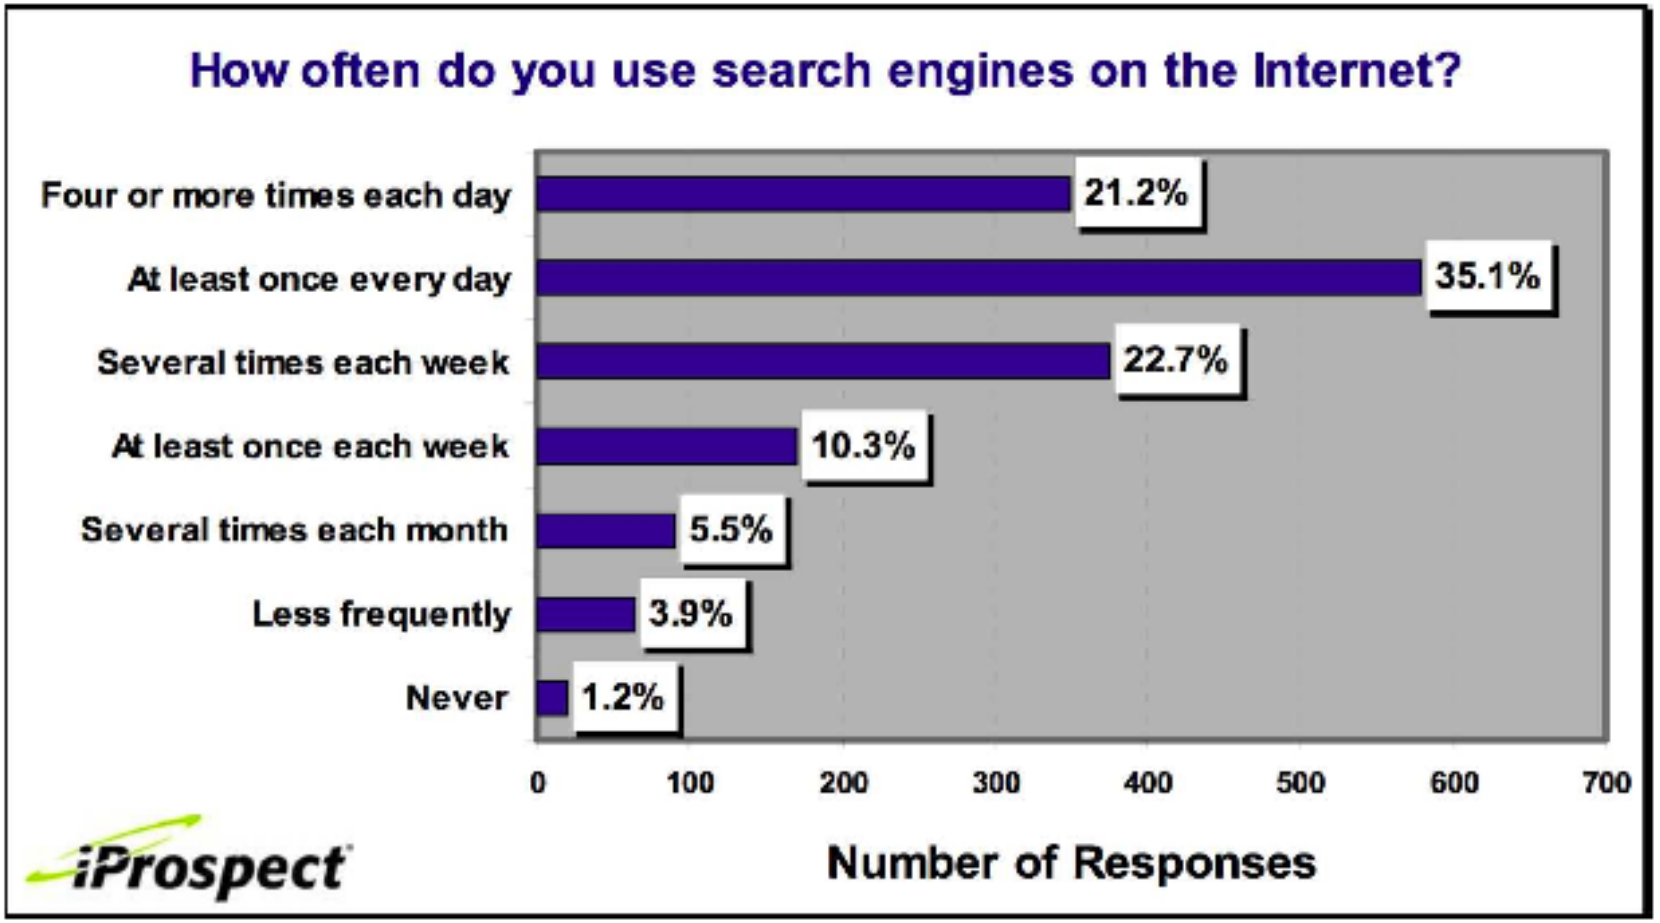

Phạm vi tìm kiếm kết quả

"When you perform a search on a search engine and don't find what you are looking for, at what point do you typically either revise your search, or move on to another search engine? (Select one)"

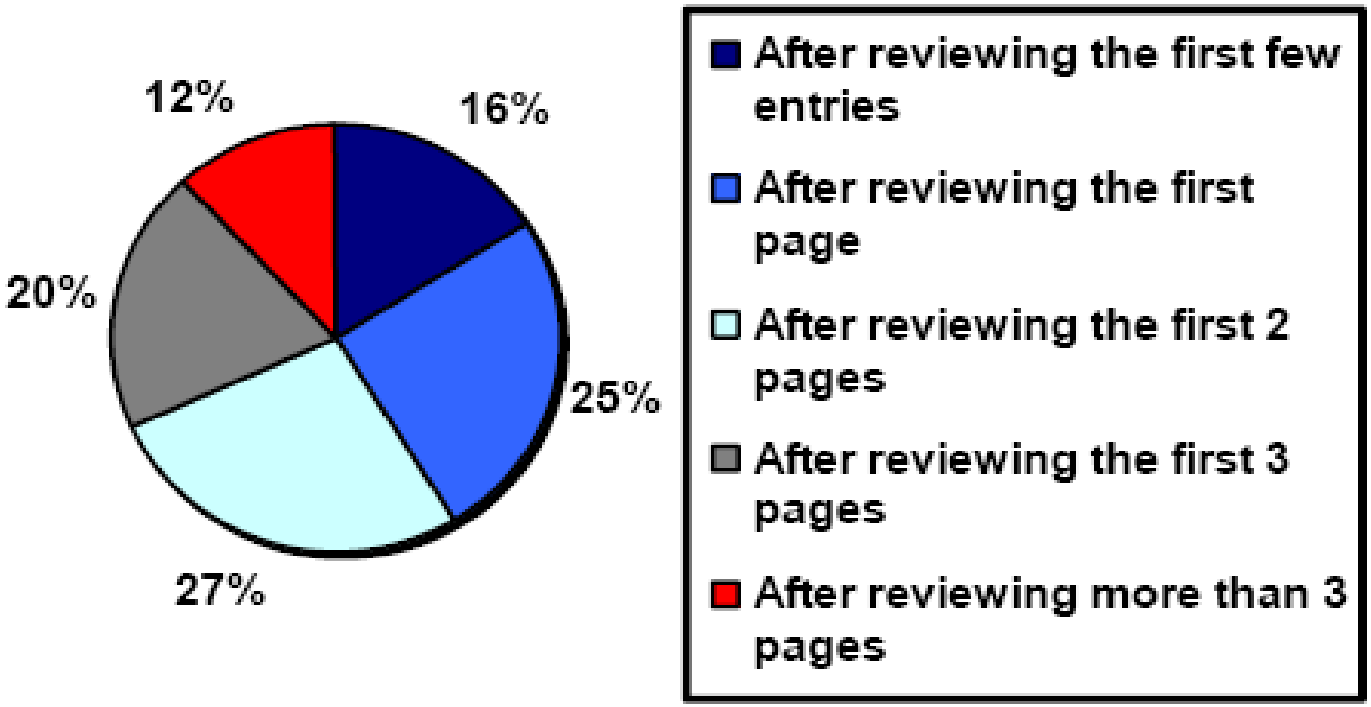

(Source: iprospect.com WhitePaper_2006_SearchEngineUserBehavior.pdf)

Tổng quan công cụ tìm kiếm trên Web

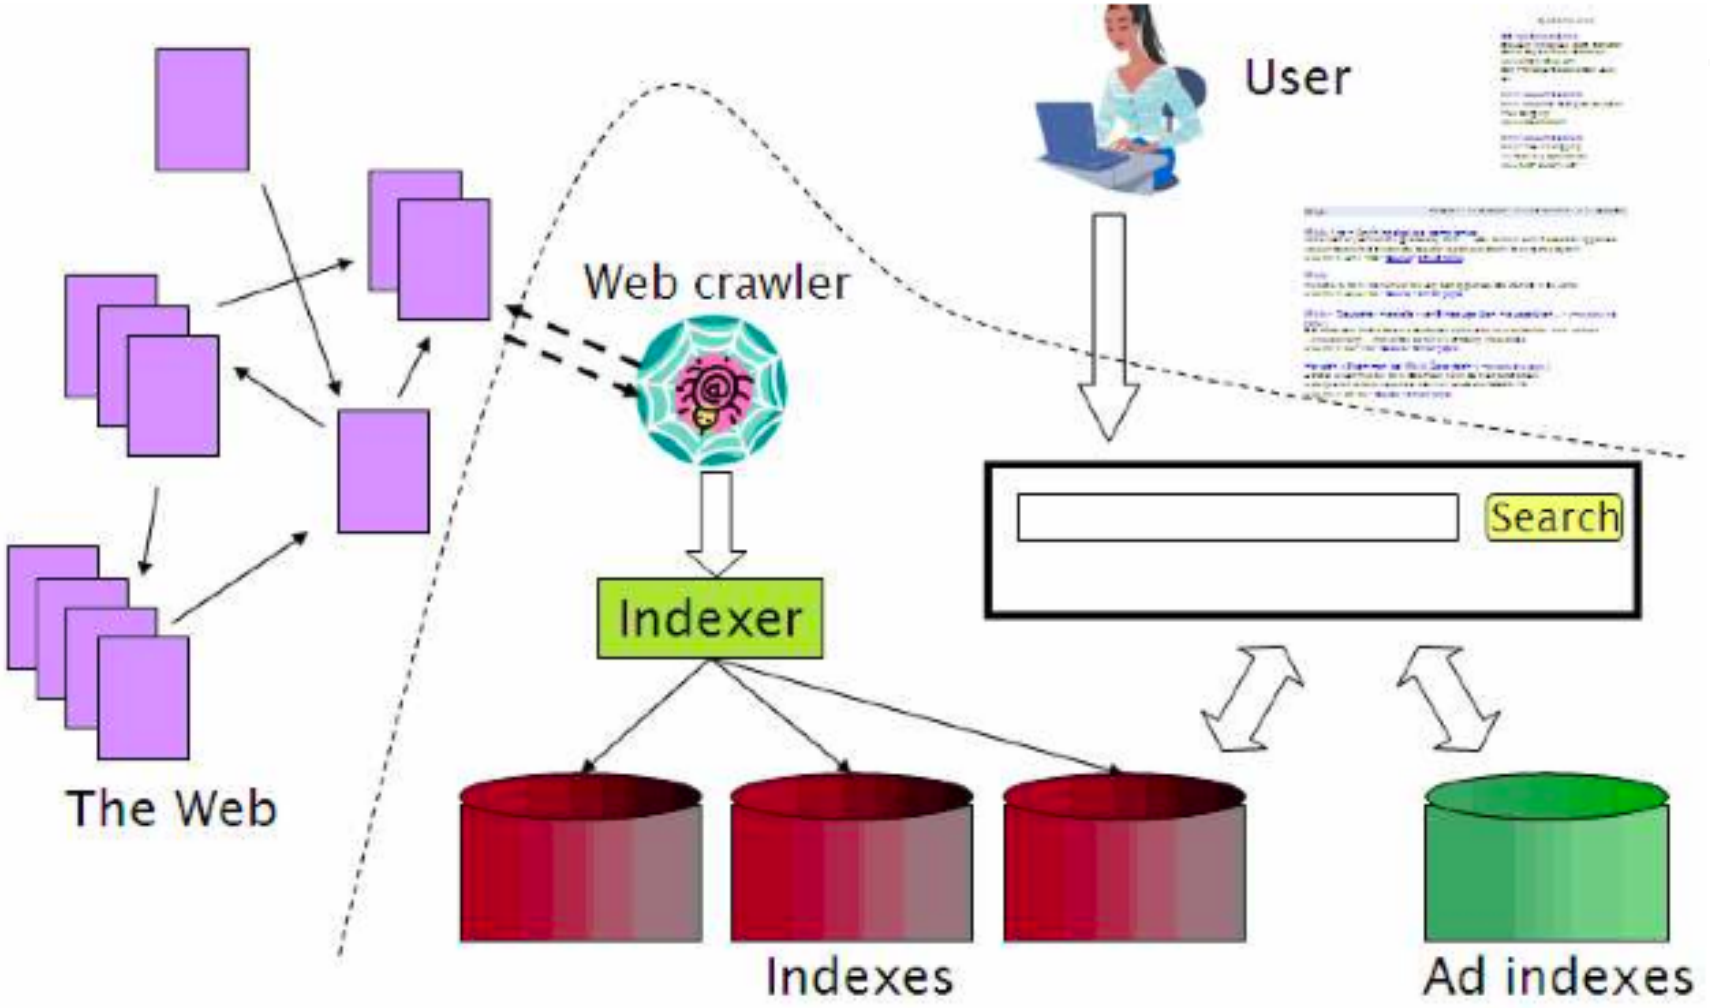

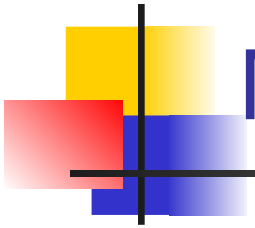

Nhu cầu thông tin

- Need [Brod02, RL04]
  - Thông tin (Informational): Học về một vấn đề nào đó (~40%/65%)
  - Định vị (Navigational): Địa chỉ một trang cụ thể (~25%/15%)
  - Giao dịch (transactional): Dịch vụ, tải dữ liệu, mua sắm, v.v., (~35%)
  - Trung gian (Gray areas)

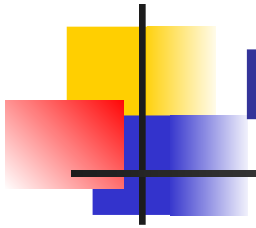

Bài tập 20.1

Nếu số trang có bậc vào i tỉ lệ thuận với $1/i^{2.1}$, bậc vào trung bình của một trang web bằng bao nhiêu?

Khi i tăng đến vô cùng điều gì sẽ sảy ra với số trang có bậc vào i: tăng, không đổi, tiến đến 0?

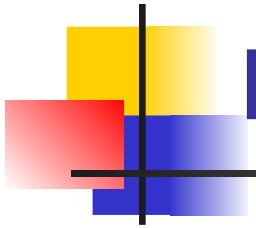

Bài tập 20.2

Giá trị trung bình bậc vào của tất cả các nút bằng 9. Giá trị trung bình bậc ra bằng bao nhiêu?

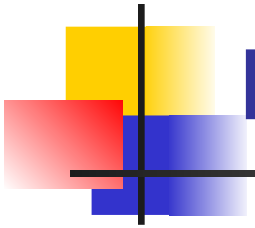

Bài tập 20.3

Hai công cụ tìm kiếm A và B sinh ngẫu nhiên một số lượng lớn trang web từ chỉ mục. 30% trang của A có trong chỉ mục của B, 50% trang của B có trong chỉ mục của A. Hãy tính tỉ lệ chỉ mục |A|/|B|