# インターネット計測とデータ解析 第 13 回

長 健二朗

2013 年 7 月 3 日

# 前回のおさらい

第 12 回 データマイニング (6/26)

- パターン抽出
- クラス分類
- クラスタリング
- 演習: クラスタリング

# 今日のテーマ

第 13 回 検索とランキング

- 検索システム
- ページランク
- 演習: PageRank

# 検索エンジンの歴史

ほとんどのインターネットユーザが毎日利用する検索エンジン

- 1994 Yahoo! ポータル開設
  - ポータルの先駆け　(ディレクトリ型)
  - 最初は自分たちのお気に入りをお勧めサイトとして公開
- 1995 Altavista
  - 検索エンジンの先駆け、ロボットによるクローリング、多言語対応
  - スパム等で精度が低下する問題
- 1998 Google サービス開始
  - Google が PageRank に基づくロボットによる検索サービス開始
  - 各ページの人気を基にスコアを算出

# 検索エンジンの仕組み

- ディレクトリ型
  - 人手による登録、分類
  - 高品質だがスケールしない
- ロボット型
  - 自動的に web を巡回してデータベースを作成
  - web page 数の増大に伴い主流に

# ロボット型検索エンジン

- web page を収集する
  - クローリング
- 収集した情報のデータベース管理
  - インデックス生成
- 検索クエリーから web page をマッチ
  - 検索ランキング

# インデックス生成

- Web page からキーワードを抽出
- キーワードから Web page への転置インデックスを作成

# 検索ランキング

検索時には、検索サーバは、

- キーワードから転置インデックスを使って、関連する Web ページのリストを得る
- リストされた Web ページをランキング順に並び変えて送信

Web ページのランキング

- Web ページの重要度を示す指標が必要
- PageRank: Google のランキング技術

# PageRank: アイデア

- Web ページのリンク関係だけからページをランキング
  - ページコンテンツはまったく見ない

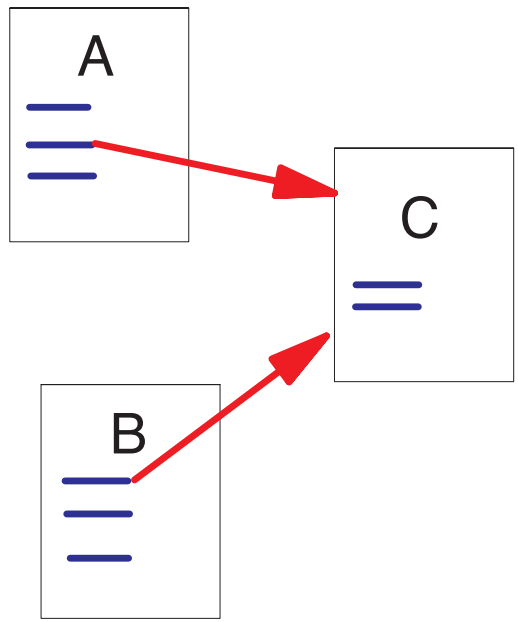


source: L. Page, et al. The pagerank citation ranking: Bringing order to the web. 1998.

# PageRank の考え方

- 良質なページは、多くのページからリンクされる
- 良質なページからのリンクは価値が高い
- ページ内のリンク数が増えると、個々のリンクの価値は減る

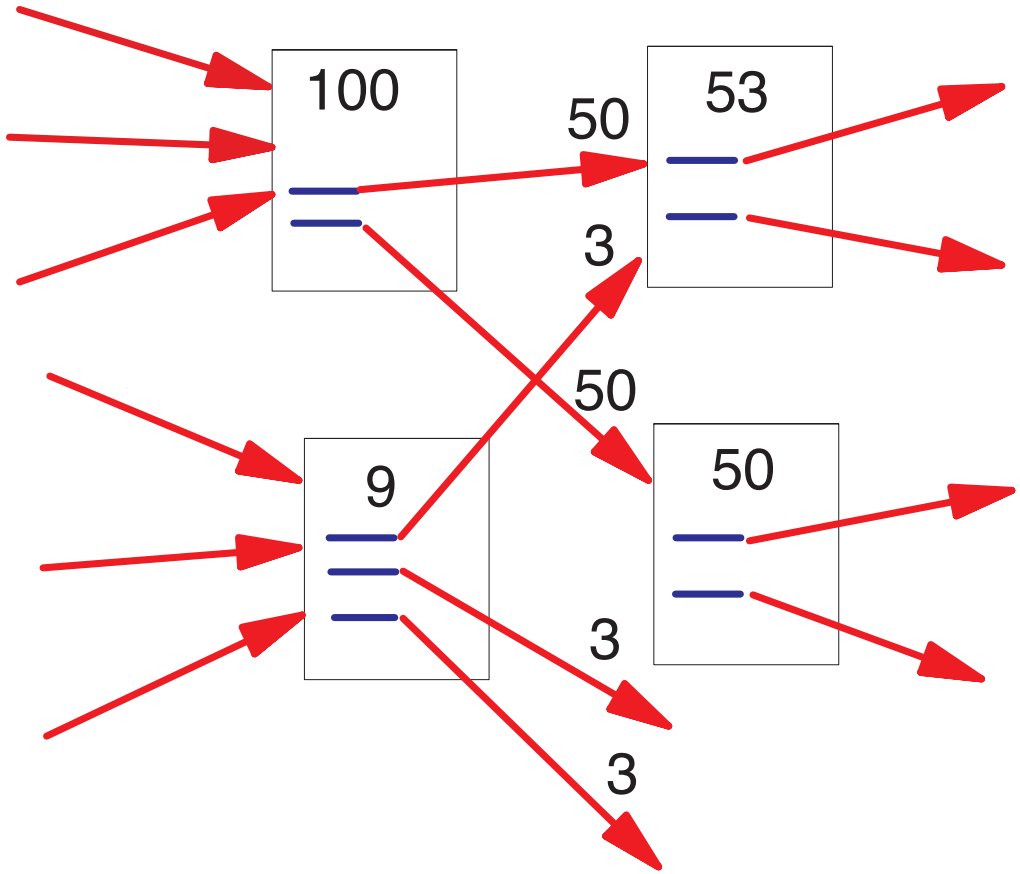


source: L. Page, et al. The pagerank citation ranking: Bringing order to the web. 1998.

# PageRank の考え方

- 良質なページからリンクされるページは良質である
- ランダムサーファーモデル
  - ページ内のリンクを同じ確率でクリックして次のページへ

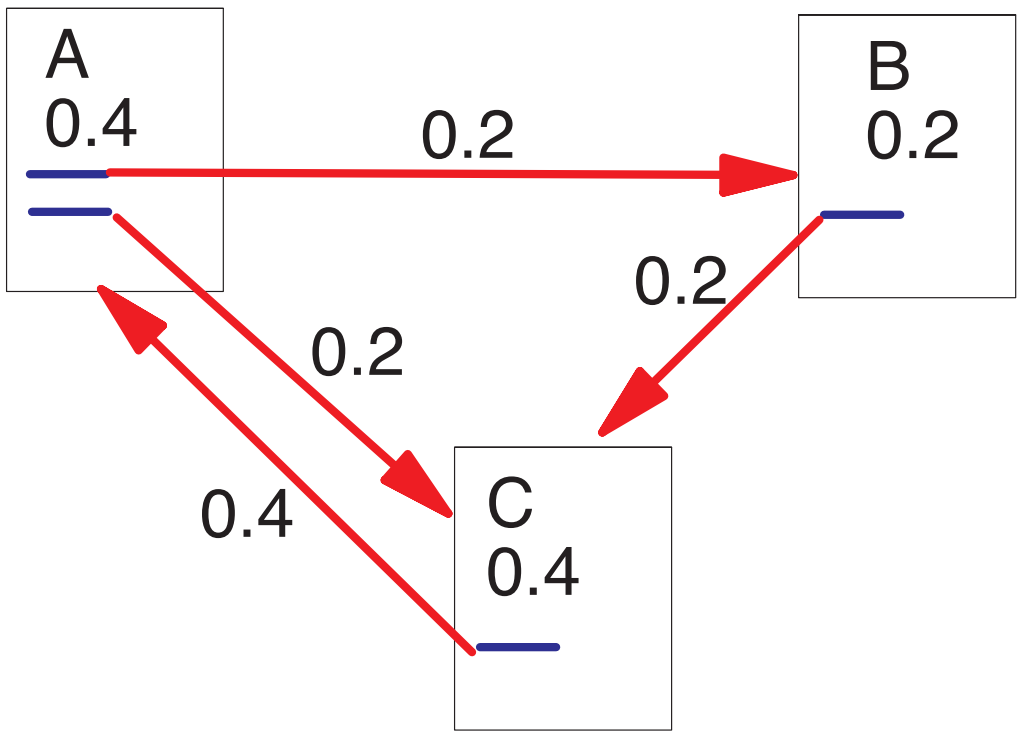


source: L. Page, et al. The pagerank citation ranking: Bringing order to the web. 1998.

# PageRank の例

| Page ID | OutLinks |
|---|---|
| 1 | 2, 3, 4, 5, 7 |
| 2 | 1 |
| 3 | 1, 2 |
| 4 | 2, 3, 5 |
| 5 | 1, 3, 4, 6 |
| 6 | 1, 5 |
| 7 | 5 |

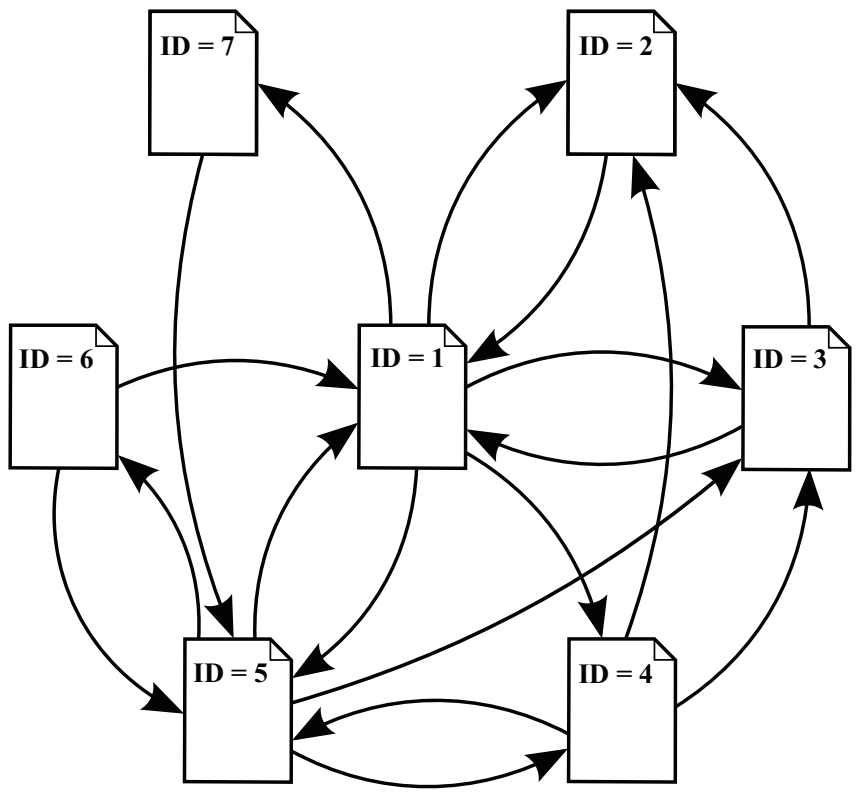

# 行列によるモデル

Matrix Notation (src $\rightarrow$ dst)

$$A^\top = \begin{bmatrix} 0 & 1 & 1 & 1 & 1 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Transition Matrix (dst $\leftarrow$ src) 列の合計は $1$

$$A = \begin{bmatrix} 0 & 1 & 1/2 & 0 & 1/4 & 1/2 & 0 \\ 1/5 & 0 & 1/2 & 1/3 & 0 & 0 & 0 \\ 1/5 & 0 & 0 & 1/3 & 1/4 & 0 & 0 \\ 1/5 & 0 & 0 & 0 & 1/4 & 0 & 0 \\ 1/5 & 0 & 0 & 1/3 & 0 & 1/2 & 1 \\ 0 & 0 & 0 & 0 & 1/4 & 0 & 0 \\ 1/5 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

$$\mathsf{R} = c\mathsf{AR}$$

ページランクベクトル $R$ は、遷移確率行列 $A$ の固有ベクトル、$c$ は固有値の逆数

# PageRank の例の計算結果

固有値計算で求まる

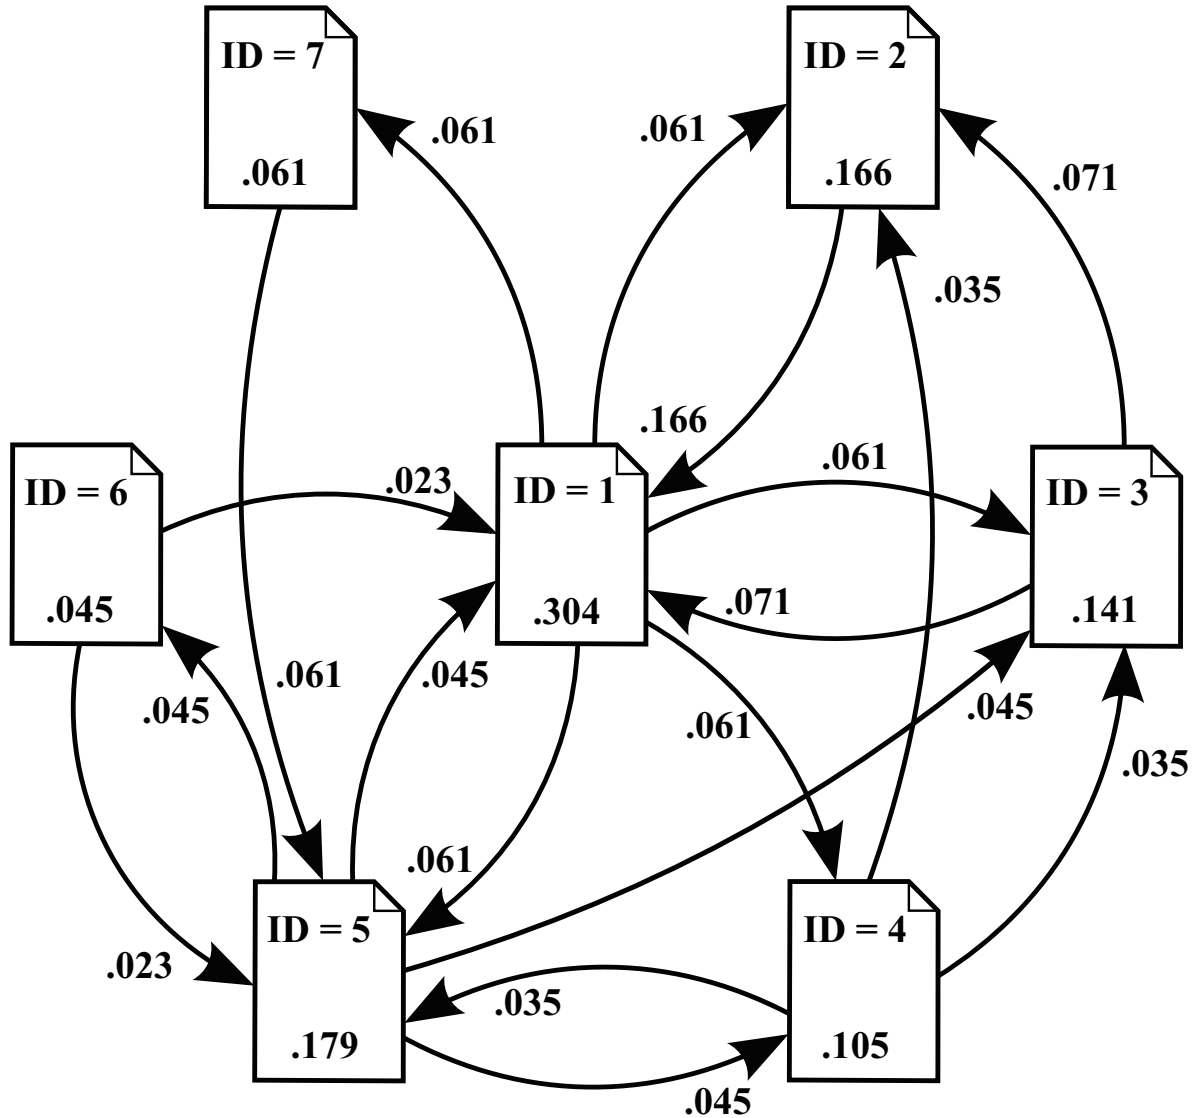

# シンプル PageRank モデルの問題

- 現実には
  - 外向きリンクがないノードが存在 (dangling node)
  - 内向きリンクがないノードが存在
  - 閉ループが存在
- 推移確率モデルはマルコフ連鎖の遷移確率行列
  - 十分時間が経過すると平衡状態に収束する
- 収束条件: 行列は再帰かつ既約
  - 有向グラフは強連結 (任意のノードから任意のノードに到達可能)
  - ひとつの優固有ベクトルが存在

解決案: 一定の確率でランダムなページに飛ぶ挙動を追加

# PageRank アルゴリズム

任意の初期値から始めて、各ページのランクが収束するまで遷移を繰り返す

- case: node with outlinks $(> 0)$
  - $d$ の確率で、ノード内のリンクをランダムに選択
  - $(1 - d)$ の確率で、ランダムなノードにジャンプ
- case: dangling node (no outlink)
  - ランダムなノードにジャンプ

$$\mathrm{A'} = d\mathrm{A} + (1 - d)[1/N]$$

d: damping factor $(= 0.85)$

# べき乗法による計算

- 固有値計算は行列が大きくなるとメモリ消費と計算量が膨大
- べき乗法による逐次繰返しによる近似

```
parameters:
    d: dampig_factor = 0.85
    thresh: convergence_threshold = 0.000001
initialize:
    for i
        r[i] = 1/N
loop:
    e = 0
    for i
        new_r[i] = d * (sum_inlink(r[j]/degree[j]) + sum_dangling(r[j])/N)
                   + (1 - d)/N
        e += |new_r[i] - r[i]|
    r = new_r
while e > thresh
```

# PageRank の収束

- 大量のページがあっても対数的に収束する実験結果

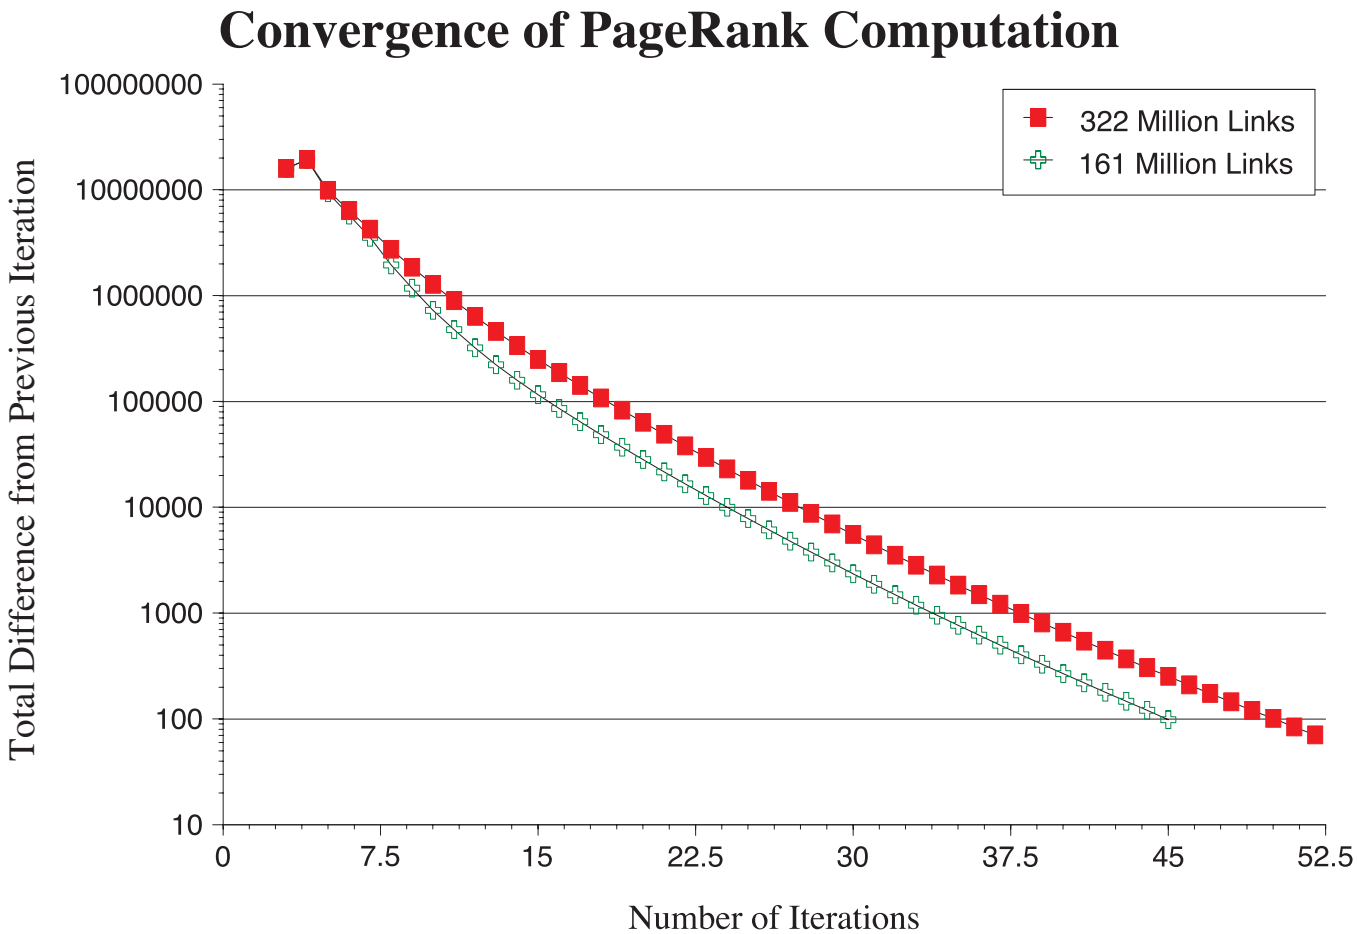


source: L. Page, et al. The pagerank citation ranking: Bringing order to the web. 1998.

# PageRank のまとめ

- シンプルなアイデア
  - 良質なページからリンクされるページは良質である
- アイデアをマルコフ遷移確率行列で定式化、収束を保証
- スケールする実装を行い、実データで有効性を実証
- ビジネスに繋げ、トップ企業に

- 注: 紹介したのは最初の論文のアルゴリズムで、現在 Google が使っているアルゴリズムは大幅に改良されているはず

# google servers

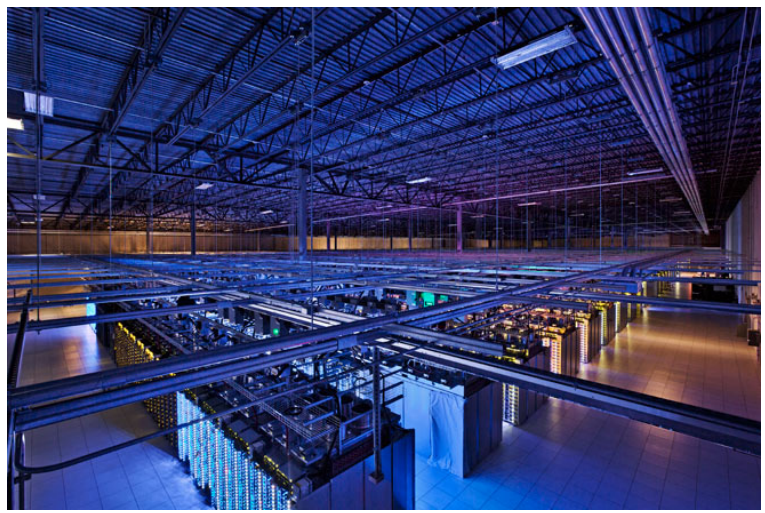

google system in 1998 and a current data center

# 今回の演習: PageRank

```
% cat sample-links.txt
# PageID: OutLinks
1:      2       3       4       5       7
2:      1
3:      1       2
4:      2       3       5
5:      1       3       4       6
6:      1       5
7:      5
% ruby pagerank.rb -f 1.0 sample-links.txt
reading input...
initializing... 7 pages dampingfactor:1.00 thresh:0.000001
iteration:1  diff_sum:0.661905 rank_sum: 1.000000
iteration:2  diff_sum:0.383333 rank_sum: 1.000000
...
iteration:20  diff_sum:0.000002 rank_sum: 1.000000
iteration:21  diff_sum:0.000001 rank_sum: 1.000000
[1] 1 0.303514
[2] 5 0.178914
[3] 2 0.166134
[4] 3 0.140575
[5] 4 0.105431
[6] 7 0.060703
[7] 6 0.044728
```

# 今回の演習: PageRank code (1/4)

```
require 'optparse'

d = 0.85   # damping factor (recommended value: 0.85)
thresh = 0.000001 # convergence threshold

OptionParser.new {|opt|
  opt.on('-f VAL', Float) {|v| d = v}
  opt.on('-t VAL', Float) {|v| thresh = v}
  opt.parse!(ARGV)
}

outdegree = Hash.new # outdegree[id]: outdegree of each page
inlinks = Hash.new # inlinks[id][src0, src1, ...]: inlinks of each page
rank = Hash.new # rank[id]: pagerank of each page
last_rank = Hash.new # last_rank[id]: pagerank at the last stage
dangling_nodes = Array.new # dangling pages: pages without outgoing link

# read a page-link file: each line is "src_id  dst_id_1 dst_id_2 ..."
ARGF.each_line do |line|
  pages = line.split(/\D+/)  # extract list of numbers
  next if line[0] == ?# || pages.empty?

  src = pages.shift.to_i  # the first column is the src
  outdegree[src] = pages.length
  if outdegree[src] == 0
    dangling_nodes.push src
  end
  pages.each do |pg|
    dst = pg.to_i
    inlinks[dst] ||= []
    inlinks[dst].push src
  end
end
```

# 今回の演習: PageRank code (2/4)

```
# initialize
# sanity check: if dst node isn't defined as src, create one as a dangling node
inlinks.each_key do |j|
  if !outdegree.has_key?(j)
    # create the corresponding src as a dangling node
    outdegree[j] = 0
    dangling_nodes.push j
  end
end

n = outdegree.length # total number of nodes
# initialize the pagerank of each page with 1/n
outdegree.each_key do |i|  # loop through all pages
  rank[i] = 1.0 / n
end
$stderr.printf " %d pages dampingfactor:%.2f thresh:%f\n", n, d, thresh
```

# 今回の演習: PageRank code (3/4)

```
# compute pagerank by power method
k = 0 # iteration number
begin
  rank_sum = 0.0  # sum of pagerank of all pages: should be 1.0
  diff_sum = 0.0  # sum of differences from the last round
  last_rank = rank.clone  # copy the entire hash of pagerank

  # compute dangling ranks
  danglingranks = 0.0
  dangling_nodes.each do |i| # loop through dangling pages
    danglingranks += last_rank[i]
  end

  # compute page rank
  outdegree.each_key do |i|  # loop through all pages
    inranks = 0.0
    # for all incoming links for i, compute
    #    inranks = sum (rank[j]/outdegree[j])
    if inlinks[i] != nil
      inlinks[i].each do |j|
        inranks += last_rank[j] / outdegree[j]
      end
    end

    rank[i] = d * (inranks + danglingranks / n) + (1.0 - d) / n
    rank_sum += rank[i]

    diff = last_rank[i] - rank[i]
    diff_sum += diff.abs
  end

  k += 1
  $stderr.printf "iteration:%d  diff_sum:%f rank_sum: %f\n", k, diff_sum, rank_sum
end while diff_sum > thresh
```

# 今回の演習: PageRank code (4/4)

```
# print pagerank in the decreasing order of the rank
# format: [position]  id  pagerank
i = 0
rank.sort_by{|k, v| -v}.each do |k, v|
  i += 1
  printf "[%d] %d %f\n", i, k, v
end
```

# 前回の演習: k-means clustering

```
% ruby k-means.rb km-data.txt > km-results.txt
```

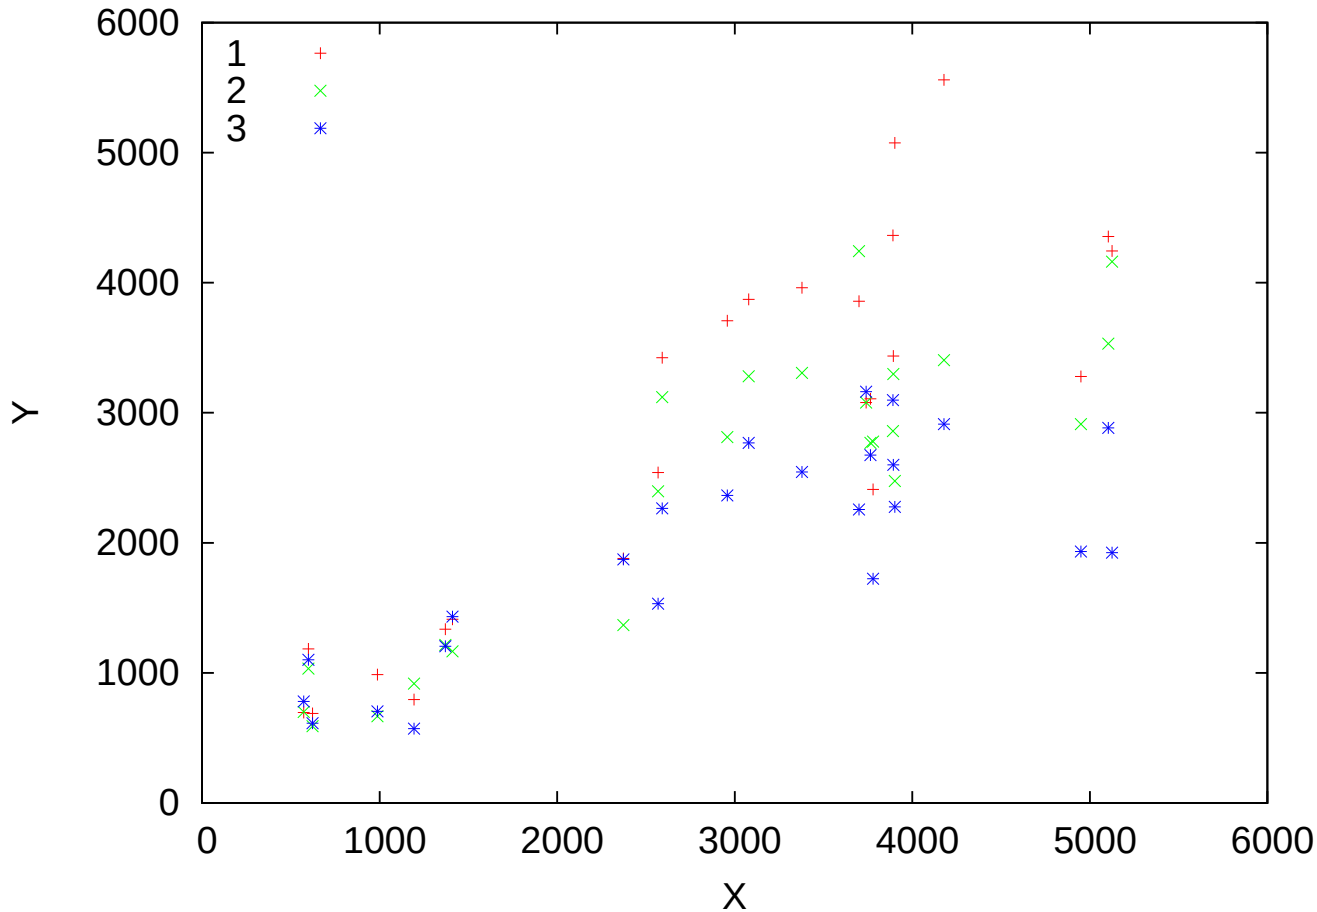

# k-means clustering results

- 初期値によって結果が異なる

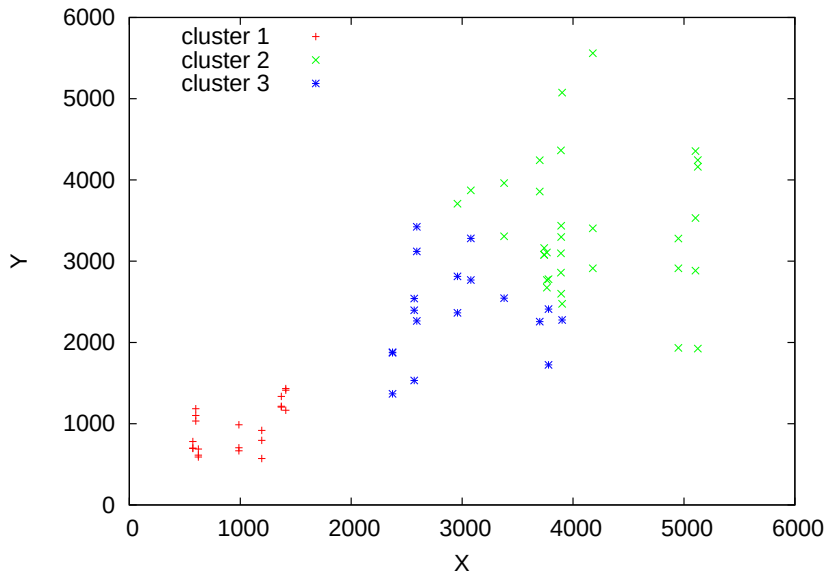


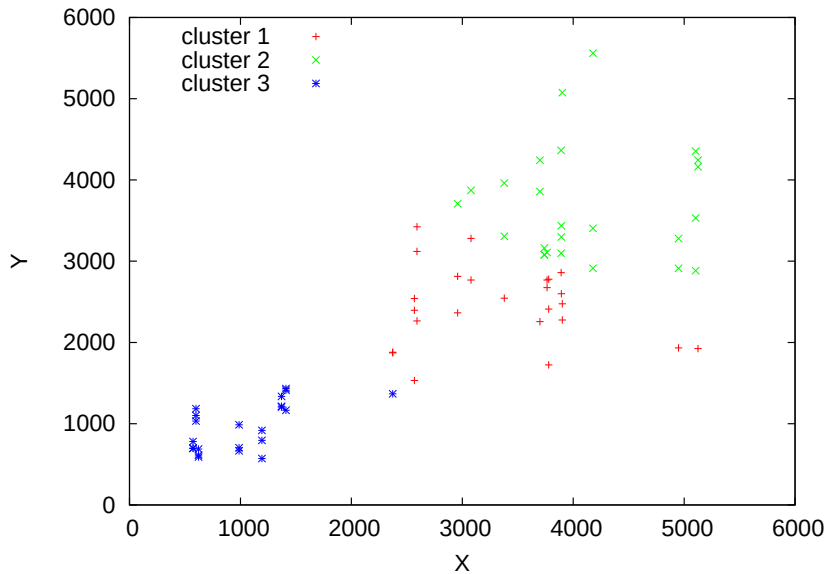

# サンプルコード (1/2)

```
k = 3 # k clusters
re = /^(\d+)\s+(\d+)/
INFINITY = 0x7fffffff

# read data
nodes = Array.new # array of array for data points: [x, y, cluster_index]
centroids = Array.new # array of array for centroids: [x, y]
ARGF.each_line do |line|
  if re.match(line)
    c = rand(k) # randomly assign initial cluster
    nodes.push [$1.to_i, $2.to_i, c]
  end
end

round = 0
begin
  updated = false

  # assignment step: assign each node to the closest centroid
  if round != 0  # skip assignment for the 1st round
    nodes.each do |node|
      dist2 = INFINITY # square of dsistance to the closest centroid
      cluster = 0 # closest cluster index
      for i in (0 .. k - 1)
        d2 = (node[0] - centroids[i][0])**2 + (node[1] - centroids[i][1])**2
        if d2 < dist2
          dist2 = d2
          cluster = i
        end
      end
      node[2] = cluster
    end
  end
```

# サンプルコード (2/2)

```
  # update step: compute new centroids
  sums = Array.new(k)
  clsize = Array.new(k)
  for i in (0 .. k - 1)
    sums[i] = [0, 0]
    clsize[i] = 0
  end
  nodes.each do |node|
    i = node[2]
    sums[i][0] += node[0]
    sums[i][1] += node[1]
    clsize[i] += 1
  end

  for i in (0 .. k - 1)
    newcenter = [Float(sums[i][0]) / clsize[i], Float(sums[i][1]) / clsize[i]]
    if round == 0 || newcenter[0] != centroids[i][0] || newcenter[1] != centroids[i][1]
      centroids[i] = newcenter
      updated = true
    end
  end

  round += 1

end while updated == true

# print the results
nodes.each do |node|
  puts "#{node[0]}\t#{node[1]}\t#{node[2]}"
end
```

# gnuplot script

```
set key left
set xrange [0:6000]
set yrange [0:6000]
set xlabel "X"
set ylabel "Y"

plot "km-results.txt" using 1:($3==0?$2:1/0) title "cluster 1" with points, \
"km-results.txt" using 1:($3==1?$2:1/0) title "cluster 2" with points, \
"km-results.txt" using 1:($3==2?$2:1/0) title "cluster 3" with points
```

# 最終レポートについて

- A, B からひとつ選択
  - A. ウィキペディア日本語版の PageRank 計算
  - B. 自由課題
- 8 ページ以内
- pdf ファイルで提出
- 提出〆切: 2013 年 7 月 30 日 (火) 23:59

# 最終レポート 選択テーマ

A. ウィキペディア日本語版の PageRank 計算

- データ: ウィキペディア日本語版のリンクデータ (170 万ページ分)
- A-1 ページの次数分布調査
  - A-1-1 各ページの出次数 (outdegree) の分布を CDF と CCDF でプロットする
  - A-1-2 ウィキペディアの出次数分布に関する考察
- A-2 PageRank の計算
  - A-2-1 PageRank を計算し、特定のキーワードを含むトップ 30 の結果を表にする
  - A-2-2 その他の解析と結果の考察

B. 自由課題

- 授業内容と関連するテーマを自分で選んでレポート
- 必ずしもネットワーク計測でなくてもよいが、何らかのデータ解析を行い、考察すること

最終レポートは考察を重視する

# 課題 A. ウィキペディア日本語版の PageRank 計算

データ: ウィキペディア日本語版のデータ (170 万ページ分)

- wikipedia が提供するデータを元に加工したもの
  - 授業ページからデータをダウンロードする
  - 元データ情報: http://ja.wikipedia.org/wiki/Wikipedia:データベースダウンロード
- links.txt: リンクデータ (219MB)
  - 各ページは、整数 $id$ で表現

```
from:  to_{1} to_{2} ... to_{n}
```

- title-cat-list.txt: タイトル・カテゴリのリスト (143MB)

```
id   "title" ###  category category2 ...
```

```
% head -n 5 links.txt
1:
2:
5: 17432 3377 6932 90949 16771 13663 18665 ...
6:
10: 49215 17432 3041 911783 155813 1034127 9721 ...
%
% head -n 5 title-cat-list.txt
1       "Wikipedia:アップロードログ 2004 年 4 月"  ###
2       "Wikipedia:削除記録/過去ログ 2002 年 12 月"        ###
5       "アンパサンド"  ###  約物 ラテン語の語句
6       "Wikipedia:Sandbox"     ###
10      "言語"  ###  言語 言語学 民族
```

# 課題 A-1 ページの次数分布調査

A-1 ページの次数分布調査

- A-1-1 各ページの出次数 (outdegree) の分布を CDF と CCDF でプロットする
  - 次数 0 もカウントすること
- A-1-2 Wikipedia の出次数分布に関する考察
  - オプションでその他の解析など

# 課題 A-2 PageRank の計算

A-2 PageRank の計算

- A-2-1 PageRank を計算し、タイトル・カテゴリに"慶應"を含むトップ 30 の結果を表にする
  - フォーマット: 順位 ページ ID PageRank 値 ページタイトル
  - 演習用スクリプトを利用すればいい
    - damping factor:0.85 thresh:0.000001 を使用すること
- A-2-2 その他の解析と結果の考察
  - オプションでその他の解析など
    - その他のキーワードでランキングを調べる
    - 処理の高速化の工夫
    - PageRank の改良案を実装してみる
  - 結果の考察

# 課題 A-2 PageRank の結果例

A-2-1 PageRank を計算し、タイトル・カテゴリに"慶應"を含むトップ 30 の結果を表にする

```
# rank   id      pagerank    title

[555]  2758569  0.000093    "慶應義塾大学"
[3312] 8777     0.000022    "福澤諭吉"
[3767] 28727    0.000020    "森鴎外"
...
```

# まとめ

第 13 回 検索とランキング

- 検索システム
- ページランク
- 演習: PageRank

# 次回予定

第 14 回 スケールする計測と解析 (7/10)

- 大規模計測
- クラウド技術
- MapReduce
- 演習: MapReduce

補講予定

- 7/17 (水) 4 限 (14:45-16:15) $\epsilon 12$

# 参考文献


[1] Ruby official site. `http://www.ruby-lang.org/`

[2] gnuplot official site. `http://gnuplot.info/`

[3] Mark Crovella and Balachander Krishnamurthy. *Internet measurement: infrastructure, traffic, and applications*. Wiley, 2006.

[4] Pang-Ning Tan, Michael Steinbach and Vipin Kumar. *Introduction to Data Mining*. Addison Wesley, 2006.

[5] Raj Jain. *The art of computer systems performance analysis*. Wiley, 1991.

[6] Toby Segaran. (當山仁健 鴨澤眞夫 訳). 集合知プログラミング. オライリージャパン. 2008.

[7] Chris Sanders. (高橋基信 宮本久仁男 監訳 岡真由美 訳). 実践パケット解析 第 *2* 版 — *Wireshark* を使ったトラブルシューティング. オライリージャパン. 2012.

[8] あきみち、空閑洋平. インターネットのカタチ. オーム社. 2011.

[9] 井上洋, 野澤昌弘. 例題で学ぶ統計的方法. 創成社, 2010.

[10] 平岡和幸, 掘玄. プログラミングのための確率統計. オーム社, 2009.