

Web Information System Design

No.8 データのWeb

萩野 達也 (hagino@sfc.keio.ac.jp)

Web文書とWebアプリケーション

▶ Web文書

- ▶
- ▶
- ▶
- ▶
- ▶

▶ Webアプリケーション

- ▶
- ▶
- ▶
- ▶
- ▶


検索エンジンは万能アプリか？

- ▶ 少ないキーワードからWeb文書を探し出す
 - ▶ 個のキーワードを与えることが多い
- ▶ 検索エンジンの仕組み
 1. Webサイトを してWeb文書を集めてくる
 - ▶ ハイパーリンクをたどる
 2. すべての単語をキーワードだと思い索引を作る
 - ▶
 3. 検索で与えられたキーワードから作品を使ってWebページを探す
 - ▶ AND, OR, NOT
 4. を使って検索結果の表示順を決める
 - ▶

ページランクのアルゴリズム


- ▶ Webページ: $p_1, p_2, \dots, p_N$
 - ▶ $M(p_i) = p_i$ にリンクしているページの集合
 - ▶ $L(p_j) = p_j$ から出ているリンクの数
 - ▶ $N =$ 前ページ数
 - ▶ $d =$ ダンピング・ファクター 0.85 (85% , 15%)
)
- ▶ ページランク: $PR(p_i)$
 - ▶ $PR(p_i) = \frac{1-d}{N} + d \sum_{p_j \in M(p_i)} \frac{PR(p_j)}{L(p_j)}$
- ▶ 計算
 - ▶ ページランクの初期値: $PR(p_i) = \frac{1}{N}$
 - ▶ 上記の式を使ってページランクを更新していく

例




page	$M(p_i)$	$L(p_j)$
A		0
B	C, D, E, F, G, H, I	1
C	B	1
D	E	2
E	F, G, H, I, J, K	3
F	E	2
G		2
H		2
I		2
J		1
K		1

例 (t=0)




page	$PR(p_i: \mathbf{0})$	$PR(p_i: \mathbf{1})$
A	9.09%	5.23%
B	9.09%	30.98%
C	9.09%	9.09%
D	9.09%	3.94%
E	9.09%	32.27%
F	9.09%	5.23%
G	9.09%	1.36%
H	9.09%	1.36%
I	9.09%	1.36%
J	9.09%	1.36%
K	9.09%	1.36%

例 (t=1)




page	$PR(p_i: 1)$	$PR(p_i: 2)$
A	5.23%	3.04%
B	30.98%	23.87%
C	9.09%	27.70%
D	3.94%	10.51%
E	32.27%	7.64%
F	5.23%	3.04%
G	1.36%	1.36%
H	1.36%	1.36%
I	1.36%	1.36%
J	1.36%	1.36%
K	1.36%	1.36%

例 (t=2)



page	$PR(p_i: 2)$	$PR(p_i: 3)$
A	3.04%	5.83%
B	23.87%	34.57%
C	27.70%	21.65%
D	10.51%	3.53%
E	7.64%	6.71%
F	3.04%	5.83%
G	1.36%	1.36%
H	1.36%	1.36%
I	1.36%	1.36%
J	1.36%	1.36%
K	1.36%	1.36%

例 (t=30)



page	$PR(p_i: 30)$
A	2.74%
B	31.16%
C	27.83%
D	3.23%
E	6.58%
F	2.74%
G	1.36%
H	1.36%
I	1.36%
J	1.36%
K	1.36%

検索エンジンで十分か？

▶ 検索エンジンができること:



▶ 検索エンジンができないこと:



Web上のデータ

▶ Webには有益なデータがたくさんある:

- ▶
- ▶
- ▶
- ▶
- ▶
- ▶
- ▶
- ▶
- ▶
- ▶

CSV

- ▶ Comma-Separated Values
 - ▶ テキスト形式
 - ▶ 列はコンマで区切られる
 - ▶ データ交換によく用いられる
 - ▶ ExcelからCSVを出力可能

World Country

```
Country,Capital,Population,Area (km2) ,Official Languages
Japan,Tokyo,126659683,377944,Japanese
United States,"Washington, D.C.",318133000,9826675,English
United Kingdom,London,63705000,243610,English
France,Paris,66616416,640679,French
China,Beijing,1350695000,9596961,Standard Chinese
India,New Delhi,1210193444,3287590,"Hindi,English"
...
...
```

XMLで表現

▶ 時刻表

```
<?xml version="1.0" encoding="Shift_JIS"?>
<timetable>
  <station name="辻堂">
    <line name="東海道" dir="上り" week="平日">
      <train at="6:02" dest="高崎" kind="計測" />
      <train at="6:11" />
      <train at="6:19" />
      <train at="6:27" dest="籠原" kind="快速" />
      ...
      <train at="6:62" kind="湘南ライナー" />
      ...
    </line>
    ...
  </station>
  ...
</timetable>
```

XMLで表現

▶ World Country

```
<?xml version="1.0" encoding="Shift_JIS"?>
<world>
  <country name="Japan">
    <capital>Tokyo</capital>
    <population>126659683</polulation>
    <area unit="km2">377944</area>
    <language>Japanese</language>
  </country>
  ...
  <country name="India">
    <capital>New Delhi</capital>
    <population>1210193444</polulation>
    <area unit="km2">3287590</area>
    <language>Hindi</language>
    <language>English</language>
  </country>
  ...
</world>
```

HTMLの表 vs CSV vs XML

	HTML の表	CSV	XML
利点			
欠点			

データベース

▶ 関係データベース

- ▶ データを表として表す
- ▶ 依存関係から正規化する
 - ▶ 主キー
- ▶ 関係代数
 - ▶ 制限, 射影, 結合
- ▶ 検索言語
 - ▶ SQL

Country

id	name	capital	population	area
1	Japan	Tokyo	126659683	377944
2	United States	Washington, D.C.	318133000	9826675
3	India	New Delhi	1210193444	3287590
...	...	...	...	...

↑
主キー

Language

country	language
1	Japanese
2	English
3	Hindi
3	English
...	...

↙ ↘
複合キー

Webデータの特徴

- ▶ 開世界である



- ▶ 複数のデータの結合



- ▶ 矛盾するデータ



データの結合

▶ 個人のCD管理

- ▶
- ▶
- ▶

▶ スケジュール管理

- ▶
- ▶
- ▶
- ▶
- ▶

▶ くすりの管理

- ▶
- ▶
- ▶

▶ 食事管理

- ▶
- ▶
- ▶

どのようなデータが欲しいか？

- ▶ どのようなデータが欲しいか？あればうれしいか？



- ▶ 現在あるデータおよびその形式は？



まとめ

▶ 文書とアプリケーション

- ▶ 静的情報
- ▶ オンラインショッピング

▶ 検索エンジン

- ▶ 全文検索
- ▶ ページランク

▶ 文書とデータ

- ▶ データ形式
- ▶ データベース
- ▶ データの組み合わせ
- ▶ AAAの原則: Anybody can say anything about any topic.
- ▶ 開世界