

サービスコンピューティング のための HTML利用基盤の確立

大阪工業大学 情報科学部
須永 宏

Copyright © OIT, SC-LAB 2012  1

本日の発表内容

- HTMLサイトの利用基盤
(特定の案件ではなくできる限り汎用的に)
- HTML5のグラフ作成機能によるグラフ表示
(サイトより取得したデータからグラフ生成)

Copyright © OIT, SC-LAB 2012  2

HTMLの利用の問題点

- HTMLは、ビジュアル重視でデータ構造など統一規格無し。統計情報サイトなどはデータの宝庫だが、XMLと違い、プログラムでの扱いは困難。
- 送信時のFormやパラメタの扱いも判りにくく、パケットモニタでHttpパケットを観測し判断することも。
- JavaScriptが使われているとさらに複雑。

しかし、XML APIで提供されていない有用な情報が無限にある！

Copyright © OIT, SC-LAB 2012  3

XML構造化文書は操作しやすい(DOM)

タグ名指定で該当タグをList形式で取り出し
`nodelist = element.getElementsByTagName("pastHistory");`
`<pastHistory>`
 `<byoumei>ヘルニア</byoumei>`
 `<timeage>2011年12月</timeage>`
 `<outcome>良好</outcome>`
 `<comment>次回再検査</comment>`
`</pastHistory>`
`<pastHistory>`
 `.....`
`</pastHistory>` 要素の取り出し
`subnodelist.item(i).getFirstChild().getNodeValue();`

Copyright © OIT, SC-LAB 2012  4

XMLの問題点=APIが少ない！

- 一般検索(Yahoo, Bing), 翻訳(Google), 地図(Google), 音楽検索(Youtube RSS), 商品検索(楽天)などいくつかの汎用的なサービスは提供されている。
- 有料化・会員限定など使いにくくなっている。
- 作りたいアプリケーションの目的に沿ったAPIが殆ど無い。

→HTMLサイトから情報を引き出したい！！！

Copyright © OIT, SC-LAB 2012  5

本研究の対象となるHTMLサイトの例

- <http://prf.uub.jp/prefbase.html>

| 2012年10月1日現在の自治体数(最新) | | | | | | | 最新 | データを再表示する | | |
|-----------------------|--------------|-------------|--------------|------------------|---------------|------|----|-----------|----|---|
| 都道府県 | 都道府県 序所在地 | 推計人口 (人) | 面積 (平方km) | 人口密度 (人/平方km) | 国勢調査人口 (人) | 市町村数 | 市 | 区 | 町 | 村 |
| 北海道 | 札幌市 | 5,485,916 | 78,420.66 | 69.05 | 5,506,419 | 35 | 10 | 129 | 15 | |
| 青森県 | 青森市 | 1,363,006 | 9,644.55 | 141.32 | 1,373,339 | 10 | | 22 | 8 | |
| 岩手県 | 盛岡市 | 1,312,756 | 15,278.89 | 85.92 | 1,330,147 | 13 | | 15 | 5 | |
| 宮城県 | 仙台市 | 2,323,224 | 7,285.77 | 318.87 | 2,348,165 | 13 | 5 | 21 | 1 | |
| 秋田県 | 秋田市 | 1,075,055 | 11,636.26 | 92.39 | 1,085,997 | 13 | | 9 | 3 | |
| 山形県 | 山形市 | 1,161,294 | 9,323.46 | 124.56 | 1,168,924 | 13 | | 19 | 3 | |
| 福島県 | 福島市 | 1,988,995 | 13,782.76 | 144.31 | 2,029,064 | 13 | | 31 | 15 | |
| 茨城県 | 水戸市 | 2,956,854 | 6,095.72 | 485.07 | 2,999,770 | 32 | | 10 | 2 | |
| 栃木県 | 宇都宮市 | 2,000,021 | 6,406.28 | 312.10 | 2,007,683 | 14 | | 12 | | |
| 群馬県 | 前橋市 | 2,000,876 | 6,362.33 | 314.49 | 2,008,068 | 12 | | 15 | 8 | |
| 埼玉県 | さいたま市 | 7,204,168 | 3,798.08 | 1,896.79 | 7,194,556 | 40 | 10 | 22 | 1 | |
| 千葉県 | 千葉市 | 6,211,820 | 5,156.61 | 1,204.63 | 6,216,289 | 36 | 6 | 17 | 1 | |
| 東京都 | 新宿区 | 13,186,562 | 2,188.67 | 6,024.92 | 13,159,388 | 26 | 23 | 5 | 6 | |
| 神奈川県 | 横浜市 | 9,059,616 | 2,415.86 | 3,750.06 | 9,048,331 | 19 | 28 | 13 | 1 | |
| 新潟県 | 新潟市 | 2,362,561 | 12,583.83 | 187.75 | 2,374,450 | 20 | 8 | 6 | 4 | |
| 富山県 | 富山市 | 1,088,409 | 4,247.61 | 256.24 | 1,093,247 | 10 | | 4 | 1 | |
| 石川県 | 金沢市 | 1,166,315 | 4,185.67 | 278.64 | 1,169,788 | 11 | | 8 | | |

Copyright © OIT, SC-LAB 2012  6

データベース内容のXML API化

- 各SQLテーブルの列名をxmlのタグにし、行を繰り返し要素にした形で、XML API形式で情報提供する。

```
<?xml version="1.0" encoding="UTF-8"?>
- <Fuken_db time="2012/11/07(水) 19:48:40">
  - <row num="1">
    <number>1</number>
    <tag1>北海道</tag1>
    <tag2>札幌市</tag2>
    <tag3>5,485,916</tag3>
    <tag4>78,420.86</tag4>
    <tag5>69.95</tag5>
    <tag6>5,506,419</tag6>
  </row>
  - <row num="2">
    <number>2</number>
    <tag1>青森県</tag1>
    <tag2>青森市</tag2>
    <tag3>1,363,006</tag3>
    <tag4>9,644.55</tag4>
    <tag5>141.32</tag5>
    <tag6>1,373,339</tag6>
  </row>
```

Copyright © OIT, SC-LAB 2012 国立 大学 13

HTML5によるグラフ描画

- SQLテーブル表示で指定した列のデータを縦軸に、指定した行数分を横軸に表す。



Copyright © OIT, SC-LAB 2012 国立 大学 14

HTML5によるグラフ描画

- 描画用JavaScriptのflotr2ライブラリの指定形式に合わせ、SQLテーブルからデータを取り出し、JSを構成する。

```
<script type="text/javascript" src="excanvas.js"></script>
<script type="text/javascript" src="vbar.js"></script>
<script type="text/javascript">
window.onload = function() {
var e = new flotr2graph.vbar("eraph");
if (!e) {return;}
var items = [
["推計人口(人)", 5485916, 1363006, 1312756, 2323224, 1075055, 1161294, 1988995, 2956954, 2000021, 2000876]
];
var params = {
x: ["都道府県", "北海道", "青森県", "岩手県", "宮城県", "秋田県", "山形県", "福島県", "茨城県", "栃木県", "群馬県"]
y: ["推計人口(人)"]
};
e.draw(items, params);
}
</script>
```

15

適用性評価

- (1)単純なテーブル構造、即ち<table>タグ配下に同じ数の<td>を持つ<tr>のみが並んでいる場合。列名とその配下のデータが一致する。
- (2)(1)の構造で一部の行(<tr>)に列の不足がある。あるいは<td>の数は揃っていないが、<td>の要素が「空」である。
- (3)<tr>や<td>内で種々の属性が入っている。
- (4)<tr><td>の間にスタイル指定などのタグが入っている。

※これらについては概ねOK。

Copyright © OIT, SC-LAB 2012 国立 大学 16

適用性評価

- (5)<table>の入れ子。即ち、テーブル内に何重かにテーブルが存在しているケース。
- (6)各行で列要素が一定でない。(2)のケースで単純に補完が出来ないようなケース。特に、タイトル行が複数行あり小計的に区分され、データの要素との一致が取りにくく複雑な構造。
- (7)HTML5のグラフ化で、系列や具体的な数値の設定においてエラーを生ずることがある。

※完全に解決してはいない。

Copyright © OIT, SC-LAB 2012 国立 大学 17

適用性評価

- (5)ではテーブル構造検索の関数(メソッド)を再帰呼び出しにて取り出していくが、SQLテーブル構造に適切に変換できないことがあるなど、一部のみ適応可能である。

- (6)は種々のケースがあり個々に対応しつつあるが、汎用的な解には至っていない。JavaのString型のreplaceFirst()メソッドなどを多用した実装で、このメソッドで対応できない文字、例えば「[,] , * 」などを見つけ次第エスケープしているが、今後も対応しきれていない箇所が出現する可能性は高い。

Copyright © OIT, SC-LAB 2012 国立 大学 18

適用性評価

OIST SC-LAB Proprietary
Osaka Institute of Technology

(7)についても、単純なケースは検証できているが、Flotr2ライブラリの限界を超える場合や、面積や人口というように単位の違うものの扱い(表示)に関して十分な対応ができない。

●なお本機能の有用性の観点の主観評価では、研究室関係の被験者(20名)から全て良好との結果を得ている。

Copyright © OIT, SC-LAB 2012  19

結論

OIST SC-LAB Proprietary
Osaka Institute of Technology

●API化と情報提供がなされれば成長が期待できる分野は色々とある。

●HTMLの解析は困難であり、通常は二次利用が認められていないので、WebサービスAPIの提供が望まれる。

●サービスコンピューティングに向けたHTMLサイト利用基盤を構築した。

Copyright © OIT, SC-LAB 2012  20