

Webデータの自動抽出とデータ変換

Automatic extraction and conversion of data from the WWW

小沼 寛明*
Hiroaki Onuma

全 眞嬉*
Jinhee Chun

徳山 豪*
Takeshi Tokuyama

1 はじめに

複数の web ページからデータを自動的に抽出しデータ変換を行い XML にまとめる。本稿では、リストページとディテールページの構造を持った web ページ群から情報を自動抽出する Lerman らの手法 [1] の実装と改善方法を提案し実験を行った。Lerman らの手法ではタグに挟まれている文字列を extract とし、リストページとディテールページの完全一致する文字列のみを抽出し、CSP の制約式を立ててレコード分割に用いる。完全一致した文字列のみ抽出されるため、情報ロスが生じる。

本稿では上記の問題を回避するための改善方法を提案する。

- 完全に文字列が一致しなくとも共通の extract として抽出を行う。
- さらに連続条件を変更し、文字列が連続で現れなくても extract のレコードへの割り当てが入れ子にならない限り同じレコードに割り当ててを許す。
- 抽出されたデータを XML 形式に変換する。

提案する方法の妥当性を調べるため実装し評価を行う。

2 問題の概要

現在、インターネットからは様々な情報を得ることができ、その多くは HTML で書かれた web ページとして提供されている。HTML は、web ページをどのように見せるかを記述する言語であり、人間が見て判りやすいように工夫されている。web データに対してラベル付け等の仕掛けが必要であり、現状ではコンピュータが web ページから直接情報として扱うことは困難である。したがって、web データを情報として利用するために、web ページからデータを抽出し、その関連を見出し、表形式のデータ変換を行いデータベースを構築する。本稿では、リスト形式の商品一覧ページをリストページと呼び、各商品の詳細な情報が記載されているページをディテールページと呼ぶ。この二種類のページからは異なる情報を得ることができる。ディテールページからは、リストページには記載されていない細かい情報が、一方リストページからは、あるカテゴリに属する商品のリストや、販売ランキングの順位などディテールページからは得られない情報を得ることができる。

リストページには商品リスト、チェックした商品の履歴、お勧め商品、広告等いろんな情報が提示されている。リストページから商品リスト情報を抽出するには、さまざまな情報から商品リストの特定、また一つの商品を表している範囲の特定をしなければならない。

この問題に対し、考えられるひとつの手法はハイパーリンクを利用する方法である。しかし、web ページはヘッダ部

やフッタ部、広告などにリストとは関係のない数多くのハイパーリンクがあるためハイパーリンクのみを用いての特定は難しい。本稿では、上記の特定作業にリンクの情報は利用せず、リストページとディテールページに共通する内容(データ)に着目して情報の抽出とデータ変換を行う。

3 情報抽出と変換のアルゴリズム

リストページとディテールページの枠組みを利用したデータ変換に関して、Lerman ら [1] が CSP (Constraint Satisfaction Problem: 制約充足問題) を用いた手法を提案している。以下はその手順である。

- テンプレートの探索およびスロットの特定
- CSP の条件式を立ててこれを解く

3.1 テンプレートの探索およびスロットの特定

上記のような企業のサイトの多くはリストページやディテールページを企業が独自に持つデータベースと連携し、web サーバがあるテンプレートを基に自動的に作り情報を提供している。我々の望む各商品の情報はテンプレートではなくそれ以外の部分(スロット)に含まれていると考えられる。スロットを特定するためには、テンプレート探索アルゴリズム [2] を用いる。

3.2 CSP によるレコード分割

リストページとディテールページに共通した内容(データ)を以下 extract と呼び、これをスロットから抽出し、レコードというものに割り当てる。同じレコードに割り当てられた extract はある同一の商品に関するデータであることになる。この作業をレコード分割と呼ぶ。なお、[1] では、HTML タグでない (HTML タグには含まれた) 部分を 1 つの extract として抽出しておりまったく同じ文字列でなければ共通のデータとして抽出しない。例えば、「980 円」、「980 円 (税込み)」の 2 つのデータは、共通のデータではないとみなされる。

以後、 x_{ij} を、 i 番目の extract E_i がレコード r_j に割り当てられるとき $x_{ij} = 1$ 、 E_i がレコード r_j に割り当てられないとき $x_{ij} = 0$ となる割り当て変数とする。CSP の制約条件として以下の 3 つを採用している。

独立条件 各 extract E_i は多くとも 1 つのレコード r_j に割り当てられる。

$$\sum_j x_{ij} \leq 1$$

連続条件 連続した番号の extract のブロックだけが、同じレコードに割り当てることができる。ある $k < n < i$ を満たす数 n があり、 $x_{nj} = 0$ ならば $x_{ij} + x_{kj} \leq 1$ 。

*東北大学大学院情報科学研究科システム情報科学専攻

位置条件 2つの extract が、あるディテールページの同じ位置に現れる (つまり同じデータ) ときは、それらは異なるレコードに割り当てられなければならない。

4 改良

本稿では上記のレコードへの割り当ての手法を改良する。改良点は以下の2つである。

4.1 部分一致の導入

以下のような条件でも共通であるとみなして、extract として抽出しレコードに割り当てる。

改善1 リストページのある extract を E_l 、ディテールページのある extract を E_d とする。「 E_l が E_d の部分文字列である」あるいは、「 E_d が E_l の部分文字列である」とき、 E_l と E_d の文字列の長さをそれぞれ、 L_l 、 L_d とし、ある正整数 k を用いて $|L_l - L_d| \leq k$ と表せるときだけ共通であるとみなす。

例えば、 E_l が「980円」、 E_d が「980円(税込み)」、 $k=5$ であった場合、 E_d が E_l を含み、その文字数の差が5なのでこの2つは共通の extract とみなすことになる。文字数の差に制限を設けたのはほとんど関係のない2つのデータを同じとみなすことを減らすためである。

4.2 連続条件の改善

同じレコードに割り当てべき extract のブロックのうち両端ではない extract が別のレコードに割り当てられてしまうとその両端は同じレコードに割り当てることができない。また、同じレコードに割り当てべき extract 系列の間にそのレコードと無関係な extract が割り込み、その extract がどのレコードにも割り当てられなければ、その前後の extract は同じレコードに割り当てられなくなってしまう。これらを改善する方法として以下のように連続条件を変えることを提案する。この変更によって、連続した番号の extract 系列しか1つのレコードに割り当てられないのではなく、番号は連続していなくとも、他のレコードに割り当てられる extract 系列と入れ子になったり交わったりしない連続したブロックの extract 群を1つのレコードに割り当てることができるようになる。

改善2 $k < n < i$ を満たす、全ての extract の番号 n 、ページ j に現れる extract の番号 k 、 i に対して、

$$x_{ij} + x_{kj} - x_{nj} + \sum_{l \neq j} x_{nl} \leq 2$$

$\sum_{l \neq j} x_{nl}$ は、extract E_n がレコード r_j 以外のレコードに割り当てられるとき1になる。つまり、 E_n がレコード r_j 以外のレコードに割り当てられるときは、もとの連続条件と同じものを表し、どのレコードにも割り当てられない ($x_{nj} = 0$ かつ $\sum_{l \neq j} x_{nl} = 0$) のとき、 E_i 、 E_k がともにレコード r_j に割り当てることができるようになる。

5 実験

前節の改善法を Java で実装し、いくつかのサイトで実行して実験を行った。実験には、対象のサイトからリストペー

表 1: 連続条件改善の結果

ディテールページ	No	extract	No	extract	No	extract	No	extract	No	extract
1.htm	1	49920728 11355	2	XGA 対応...	4	LCM- ...	5	発売日: 2005年 12月下旬	6	1024ドット ×768...
2.htm	7	49571800 59068	8	電源 内蔵...	10	LCD- ...	11	発売日: 2005年 11月下旬	12	XGA対応 15型...

ジとディテールページをダウンロードしてきて行っている。CSP はフリーウェアのソルバーである GLPK [3] を用いて、できるだけ多くの extract が割り当てられるように線形計画問題として解き、レコードへの割り当てを求めている。

5.1 部分一致の導入の結果

実験の結果、部分一致した文字列も共通の extract ととして抽出するようになったことにより、より多くのデータをレコードに割り当てることができるようになった。

しかし、制限を緩めたことであまり関係のないデータも共通の extract ととしてレコードに割り当ててしまうという場合もあった。文字数の差 k でこれを改善しようとしたが、更に他の改善方法の考案が今後の課題である。

5.2 連続条件の改善の結果

表 1 はディスプレイを販売するある企業のサイトでの結果である。一番目、二番目のレコードそれぞれ、3,9番目の extract が割り当てられていないが、その前後の extract 系列が同じレコードに割り当てられ、正しく動作していることが確認できた。

6 終わりに

提案する改善法を実装し、実験により自動抽出精度が上がった事を示した。今後の課題としては、さらにレコード分割の精度を上げる事を考える。

参考文献

- [1] Kristina Lerman, Lise Getoor, Steven Minton, Craig Knoblock. Using the Structure of Web Sites for Automatic Segmentation of Tables, *Proceedings of the 2004 ACM SIGMOD international conference on Management of data* 119-130.
- [2] K.Lerman, S.Minton, and C.Knoblock. Wrapper maintenance: A machine learning approach. *Journal of Artificial Intelligence Research*, 18:149-181, 2003.
- [3] GLPK
<<http://www.gnu.org/software/glpk/glpk.html>>