

医療論文抄録からの情報抽出のための並列表現分析 ～診断、治療の評価項目を含む表現～

1 R-7

井上 大悟* 永井 秀利* 中村 貞吾* 野村浩郷* 中島 律子† 大貝 晴俊‡

九州工業大学 情報工学部* 科学技術振興事業団† 新日鉄‡

1 背景

近年、医療分野における診断機器や治療方法の向上は著しく、それにコンピュータ、ネットワークの発展、普及も重なって、カルテや医療文献など多種多様な医療情報が電子化されるようになった。このため多くの電子化された文書から計算機によって情報を抽出するシステムが実現することによって得られるメリットは非常に大きいため、現在盛んに研究されている。

これまでの研究で、抽出したい情報項目が 1 文中に 1 回しか出現しないような場合、それらの文には定型性が見受けられ、抽出する項目とその周辺の文字列を記述した“テンプレート”を使用することで、ある程度の抽出結果を得ることができた [1]。しかし、医療論文抄録は限られた字数で記述するため、診断、治療を行った結果部分について記述している一文においては抽出したい情報が詰めこまれていることが多い。そのため、抽出したい情報項目が 1 文中に 2 回以上出現する場合、先述した手法ではよい抽出結果を得ることができなかった。そこで、本稿では設定した抽出項目の並列表現に対し抽出を行うことを目的としている。

2 医療論文抄録と抽出項目の設定

今回対象とした医療論文抄録は 1999 年度日本医学放射線学会学術発表会抄録 236 稿と 2000 年度分 573 稿の合計 809 稿である。

また、抽出の対象とする項目は以下の 4 つを設定した。今回、これらの項目を抽出対象に設定した理由としてこれらの項目の並列表現が瀬出しているからである。

項目名	定義	記号
診療 Gr 分類	診断、治療の評価の分類グループ名	b
評価項目	診断、治療の評価項目、評価尺度	p
評価値	診断、治療の数値による評価値	v
評価単位	診断、治療の評価値の単位	u

表 1: 設定した抽出項目

抄録中に出現する以下のような文面における、各項目に対応する解を示す。

不鮮明な境界は良性腫瘍 6 病変と悪性腫瘍 1 3 病変で認め、周囲浸潤は良性 3 病変と悪性 7 病変でみられた。

記述例

b =不鮮明な境界, p =良性腫瘍, $v=6$, u =病変, p =悪性腫瘍, $v=13$, u =病変 b =周囲浸潤, p =良性, $v=3$, u =病変, p =悪性, $v=7$, u =病変

3 出現パターン

今回、設定した項目は各項目どうしが組となり文中に出現し、その組が 1 文中に複数組出現するものが多い。よって、出現パターンを調べることで、部分テンプレートを作成する鍵となる。本稿では並列表現を分析するにあたり、2000 年度分 573 稿の医療論文抄録を用いた。

●項目どうしの出現パターン

先ほどの例における項目の出現パターンを項目の記号を用いて表すと

(1) $b-p-v-u-p-v-u-b-p-v-u-p-v-u$

となる。そこで $(x-y)?$ を $x-y$ の組み合わせが連続して出現するものと定義すると、(1) のパターンは

(1-1) $(b-(p-v-u))?$?

と表現することができる。

出現タイプ	出現パターン	頻度
1	$b-(p-v-u)?$	218 文
2	$(p-v-u)?$	126 文
3	$p-v-u$	52 文
4	$(b-(p-v-u))?$?	34 文
5	$p-(v-u)?$	24 文
6	$(b-(p-(v-u))?)?$?	23 文
7	$(b)?-p-(v-u)?$	20 文
8	$(b-(v-u-p))?$?	19 文
9	$(v-u-p)?$	18 文
10	$(p)?-v-u$	12 文
11	$b-(p)?-(v-u)?$	12 文
12	$(p)?-(v-u)?$	10 文
13	$b-(p)?-v-u$	5 文
14	$p-v-u-v-u-p$	4 文
15	$b-(v-u-p)?$	4 文
16	$((p)?-b-(v-u))?$?	4 文
17	$(p)?-(v)?-u$	4 文

表 2: 1 文中の出現パターンの分類

表 2 に照らし合わせると先ほどの例 (1-1) は出現タイプ 4 に相当する。また、表 2 より調べた文において、並列構造となっている文は 533 文で 90% 以上の割合で並列構造を成していることがわかる。

●項目間の対応

1 つの評価値 (v) に対して 1 つの評価単位 (u) が出現している ($v-u$)

