

## 係り受け関係を用いた文節候補選択についての一考察

5E-7

柿ヶ原 康二 森元 遼

ATR自動翻訳電話研究所

### 1. はじめに

電話による、異なる言語間のコミュニケーションをはかる自動翻訳電話システムを実現するには、音声認識、機械翻訳、音声合成の3つの技術の確立が必要である。特に、音声認識には認識誤りがあり、認識率を上げるためにには言語情報の効果的な利用が必要である。

音声認識結果が文節ラティスになっている場合に係り受け関係を用いて最適な文節候補を選択する手法がいくつか提案されている<sup>[1]-[4]</sup>。これらは最適文節候補を効率良く求めるものであり、係り受けの曖昧性が高い場合に有効である。しかしながら限定されたタスクにおいては係り受けの曖昧性は低く、無駄な探索を行ってしまう。また、係り受け関係だけではその文の持つ深い意味などを抽出することは困難であり、そのためにはなんらかのパーサが必要になる。しかし、文節ラティスをそのままパーサの入力とするとその組み合せ数が膨大なものとなり、満足のいく処理時間が得られない。すなわち、比較的簡単な手法で文節候補を選択し、それをパーサの入力とすることが現実的である。また、文節候補の選択においてその優先度の高いものから順次求めることにより、パーサとの並列処理が可能になる。

本稿では、限定されたタスクでの対話文音声認識結果の文節ラティスから、文節間の係り受け関係を用いて優先度の高い文節から順次候補を選択する手法について報告する。

### 2. 対象とする対話文

タスクは『国際会議の参加に関する問い合わせ』を想定しており、それを構成している発話は大部分が質問文とその応答文である。

### 3. 係り受けによる文節候補の選択処理

#### 3.1 係り受けの条件

係り受けの条件としてつぎの2つを考える。

- [K1] 係りの唯一性: 文末の文節以外の文節は必ずそれより後の文節の1つにかかる。
- [K2] 係り受けの非交差性: 2つの文節の係り受け関係は他の2つの文節の係り受け関係と交差しない。

#### 3.2 係り受けデータ

係り受けによる文節候補選択を行うための辞書データとして、上記タスクのもとで収集している

対話文から係り受け関係を抽出している。現在、39200語の対話文から8476個の係り受けデータを作成している。この係り受けデータに対して係り受け関係のある文節間の距離を示したものが表1である。表1からわかるように62.4%の文節がその隣りの文節に係っており、文節間の距離が係り受けの整合度に大きく影響している。

表1 係り受け関係にある文節間の距離

距離	比率(%)
1	62.4
2	17.2
3	10.3
4以上	10.1

### 3.3 係り受けの整合度

文節候補を選択する際に2文節間の係り受けの整合度P(x,y)を調べるのであるが、それには係り受けの出現頻度F(x,y)、係り受けの距離D(x,y)、各文節の認識スコアS(y)を考慮する。現在は次式により整合度を求めている。

$$P(x,y) = F(x,y) - W1 \cdot D(x,y) + W2 \cdot S(y) \quad (W\text{は定数})$$

### 3.4 部分文節ラティス

文節ラティス内の文節に対して係り受け関係を調べる際に、係り受け関係の付けられていない部分文節ラティスが存在する。これは図1に示されるように係り受け関係のある文節にはさまれている。このとき部分文節ラティスの右端の文節候補は、部分文節ラティスに右接する文節が部分文節ラティスに左接する文節の係り先の文節に到達するまでの係り受け関係のある文節jh( $1 \leq h \leq m$ )のいずれかに係る。とくに文節jhの系列の文節数が1つの場合には図2に示されるように部分文節ラティスの右端の文節候補は文節jのみに係る。




図1 部分文節ラティス

文頭を含む部分文節ラティスに対しても同様である。文末を含む部分文節ラティスにおいてはそのラティス内のいずれかの文節に文末を含む部分文節ラティスに左接する文節が係る。




図2 部分文節ラティス

### 3.5 係り受け関係のサーチ

ある文節と他の文節との係り受け関係をサーチする場合、次の2種類のサーチを考える。

(1)右方向サーチ：ある文節*i*に右接する部分文節ラティスに対して、文節*i*と係り受け関係があり、整合度の最も高い文節*j*をサーチする。ただし、1つの文節の文節候補群に自立語の部分の同じ文節が複数存在する場合には、そのグループに係るものとする。




図3 右方向サーチ

(2)左方向サーチ：ある文節*j*に左接する部分文節ラティスに対して、その右端の文節候補の中で文節 *j<sub>h</sub>* ( $1 \leq h \leq m$ ) と係り受け関係があり、整合度の最も高い文節*k*をサーチする。




図4 左方向サーチ

### 4. 文節候補選択処理手順

上で説明した部分文節ラティスの特性とサーチの方法を用いて文節候補を選択する手順を図5に示す。この手法は優先度の高い文節から順に文節候補群を選択するものであり、認識スコアが高く明らかに正解である文節候補が存在する場合や、文脈情報などから出現する確率の高い文節候補が存在する場合に、その文節から係り受けのサーチを開始する。まず右方向サーチにより文末の文節まで係り受けの整合度の高い文節系列を求め、次に文末寄りの部分文節ラティスに対して左方向サーチにより係り受けの整合度の高い文節をサーチし、部分文節ラティスがなくなるまで繰り返す。最適候補は求まらないが比較的はやい段階で正解の文節群が選択される。

実際に5個のサンプル文を用いて、文節認識率が73%の音声認識処理の文節ラティスに対して文節候補選択を行い、認識スコアのみでスコアの高い文節候補群を選択した場合と比較した結果が表2である。表から分かるように係り受け関係を用いると、はやい段階で正解の文節群が選択される。




図5 文節候補選択処理手順

表2 正解の文節群が選択される順位

サンプル文	文節数	認識スコアのみ	係り受け
no.1	5	5	1
no.2	5	37	3
no.3	6	58	1
no.4	7	26	6
no.5	4	5	2

### 5. おわりに

限定したタスクのもとで、音声認識結果の文節ラティスに対して文節間の係り受け関係を用いて優先度の高い文節候補群を順次選択する手法を示した。今後はさらに多くの係り受けデータを収集し検討を加えたい。

#### 謝辞

本研究の機会を与えて下さるとともに適切な助言を述べられた樽松明社長に感謝する。また御討論いただいた自動翻訳電話研究所の諸氏に感謝する。

#### 参考文献

- [1] 尾関：「多文節間の係り受け整合度に基づき最適文節列を選択する多段決定アルゴリズム」信学論J71-D(1988-04)
- [2] 松永他：「係り受け規則により候補を限定した文節音声の認識」信学技法SP87-29(1987-06)
- [3] 中川他：「音節標準パターンと逆時間向き係り受け解析法を用いた日本語文音声の認識」信学論J70-D(1987-12)
- [4] 好田：「文節ラティス上で最適文節列を選択するためのアルゴリズム」信学技法SP86-72(1986-12)