

カテゴリ間の遷移情報を用いた文認識系の能力評価法*

7C-5 大槻恭士¹ 伊藤彰則² 牧野正三¹ 曽根敏夫³

¹東北大応情研 ²東北大情教セ ³東北大通研

1 まえがき

言語情報を用いて単語ラティスから文を決定する文認識系における単語認識率と文認識率の関係は、タスク中の距離1の文の数より推定することができる⁽¹⁾が、品詞等のカテゴリの bigram や trigram の有無を用いた場合の、距離1の文の数の求め方は明らかになっていない。本稿ではそれを求めるアルゴリズムを提案し、単語認識率と文認識率の関係を推定する。

2 認識系のモデル

図1にカテゴリの bigram,trigram を利用した文認識系のモデルを示す。カテゴリの bigram,trigram より生成可能なカテゴリ系列と単語辞書より可能な単語系列を生成し(図2)，単語認識系の出力と照合して文を決定する。




図1: カテゴリの bigram,trigram を利用した文認識系のモデル




図2: カテゴリ系列の単語辞書による展開

この場合、単語認識率と文認識率の関係は、全単語系列中の距離1の文の数を計算して、我々が提案した評価式⁽¹⁾によって推定することが可能であるが、その単語系列の数は語彙数とともに大きくなり、単純な距離計算は困難となる。文 $S =$

*The performance evaluation method on sentence recognition system which uses the transition information between word categories. by T.Otsuki¹, A.Ito², S.Makino¹ and T.Sone³.

¹R.C.A.I.S., Tohoku Univ. ²E.C.I.P., Tohoku Univ. ³R.I.E.C., Tohoku Univ.

$s_1 s_2 \cdots s_L$ と文 $T = t_1 t_2 \cdots t_L$ 間の距離 $D(S, T)$ は、

$$D(S, T) = \sum_{i=1}^L f(s_i, t_i), \quad f(a, b) = \begin{cases} 0 & \text{if } a = b \\ 1 & \text{else} \end{cases} \quad (1)$$

と定義される。そこで、可能な全ての単語系列中の距離1の文の数を計算するために、次に述べるようなアルゴリズムを提案する。

3 アルゴリズム

trigram は bigram に変形可能であるから、ここでは bigram について説明を行う。まず、以下のように記号を定義する。

- M : カテゴリの種類数
 - c_1, c_2, \dots, c_M : カテゴリ
 - c_s, c_e : 始端、終端を表す仮想的なカテゴリ
 - L : 文の長さ
 - $X = x_1 x_2 \cdots x_L$: 長さ L の文
 - x_i : 文 X の始端から i 番目の単語
 - $N_d(X)$: 文 X と距離が d である単語系列の数
 - $\Lambda(c)$: カテゴリ c に属する単語の数
 - $V(x)$: 単語 x の属するカテゴリ
 - Ω_l : 長さ l の生成可能な全系列
 - Ω_l^c : Ω_l 中の終端のカテゴリが c のもの
 - X_l : X の部分列 $x_1 x_2 \cdots x_l$
 - $N_d(X_l, \Omega_l^c)$: Ω_l^c 中の X_l との距離が d である系列の数
 - $s_c: c$ を出力する状態
 - $I_t(c, c')$: 遷移情報
- $$I_t(c, c') = \begin{cases} 1 & \text{if } s_c \rightarrow s_{c'} \text{ is possible} \\ 0 & \text{if } s_c \rightarrow s_{c'} \text{ is impossible} \end{cases}$$

文 X も当然生成可能な単語系列であるから $X_l \in \Omega_l$ であり、明らかに次式が成り立つ。

$$N_0(X_l, \Omega_l^c) = \begin{cases} 1 & \text{if } c = V(x_l) \\ 0 & \text{else} \end{cases} \quad (2)$$

ここで Ω_{l-1} 中の1つの系列を考える。これが次に s_c に遷移したとき $\Lambda(c)$ 個の系列に展開されるが、ここで $c = V(x_l)$ なら、展開された系列の中の終端が x_l の系列1つは X_l との距離は遷移前の X_{l-1} との距離と同じである。しかし、残りの $\Lambda(c)-1$ 個の系列では、 X_l との距離は遷移前の X_{l-1} との距離より1増加したものになる。よって、 $N_1(X_l, \Omega_l^c)$ は Ω_{l-1} のうち X_{l-1} と距離1で s_c に遷移が可能な系列の数と、 Ω_{l-1} のうち X_{l-1} と距離0で s_c に遷移が可能な系列の数に $\Lambda(c)-1$ を掛けたものとの和とな

る。一方、 $c \neq V(x_l)$ なら、展開された全ての系列で、 X_l との距離が X_{l-1} との距離より 1 増加したものになる。よって、 $N_1(X_l, \Omega_l^c)$ は Ω_{l-1}^c のうち X_{l-1} と距離 0 で s_c に遷移が可能な系列の数に $\Lambda(c)$ を掛けたものとなる。以上を式で表すと次式となり、 $N_1(X_l, \Omega_l^c)$ は逐次的に計算が可能である。

$$N_1(X_l, \Omega_l^c) = \begin{cases} \sum_{i=1}^M \{ N_1(X_{l-1}, \Omega_{l-1}^{c_i}) \\ + (\Lambda(c) - 1) N_0(X_{l-1}, \Omega_{l-1}^{c_i}) \} I_t(c_i, c) & \text{if } c = V(x_l) \\ \sum_{i=1}^M \Lambda(c) N_0(X_{l-1}, \Omega_{l-1}^{c_i}) I_t(c_i, c) & \text{else} \end{cases} \quad (3)$$

最終的に生成可能な単語系列集合中の、文 X と距離 1 である系列の数 $N_1(X)$ は次式で求まる。

$$N_1(X) = \sum_{i=1}^M N_1(X_L, \Omega_L^{c_i}) I_t(c_i, c_e) \quad (4)$$

$N_1(X)$ を求める具体的な計算手順を pascal 風に記述したものを図 3 に示す。最も計算量の多い図 3 の Step 3 について計算量をみると、いちばん外側のループが $L-1$ 回、1 つ内側のループが M 回、最も内側のループが最大 M 回で、このアルゴリズムの 1 文当たりの時間計算量は $O(LM^2)$ である。

4 単語認識率と文認識率の関係

論説文 136 文を形態素解析し品詞の列に変換したものより、品詞の bigram と trigram の有無を求めた。単語数は 496 語で、カテゴリとして、文節構造を表すオートマトン⁽²⁾ より抽出した 67 品詞を設定した。そして 136 文それぞれについて、提案したアルゴリズムによって距離 1 の文の数を求め、我々の提案した評価式によって単語認識率と文認識率の関係を推定した。併せて 136 文の文認識のシミュレーションも行った。

推定値とシミュレーションの結果を図 4 に示す。推定値よりシミュレーションの方がかなり高い文認識率を示している。設定した品詞が多く平均文長 9.8 単語と長いため、距離 1 の文の数が多く、評価式の精度が落ちてしまったと考えられる。しかし、bigram,trigram 双方の相対的な傾向は十分示されている。

5 まとめ

品詞等のカテゴリの bigram や trigram の有無を用いた文認識系の単語認識率と文認識率の関係を推定するための、距離 1 の文の数を計算するアルゴリズムを提案した。1 文に対する距離 1 の文の数を計算するのに要する計算量は、長さを L 、カテゴリの種類数を M とすると $O(LM^2)$ である。

参考文献

- (1) 大槻他: 音講論, 2-Q-6(1992-10)
- (2) 伊藤他: 信学技報, SP87-104(1987-12)

```

Step 1 :(M: カテゴリの種類数, L: 長さ)
  for all 1 < i < M, 1 < l < L do
    N0(Xl, Ωlci) := 0
    N1(Xl, Ωlci) := 0
Step 2 :
  for i := 1 to M do begin
    if ci = V(x1) then begin
      N0(X1, Ω1ci) := It(cs, ci)
      N1(X1, Ω1ci) := It(cs, ci) × (Λ(ci) - 1)
    end
    else N1(X1, Ω1ci) := It(cs, ci) × Λ(ci)
  end
Step 3 :
  for l := 2 to L do begin
    for i := 1 to M do begin
      if ci = V(xl) then begin
        N0(Xl, Ωlci) := 1
        for j := 1 to M do begin
          N1(Xl, Ωlci) := N1(Xl, Ωlci)
            + {N1(Xl-1, Ωl-1cj) + (Λ(ci) - 1)
            × N0(Xl-1, Ωl-1cj)} × It(cj, ci)
        end
      end
    end
    else begin
      N0(Xl, Ωlci) := 0
      for j := 1 to M do begin
        N1(Xl, Ωlci) := N1(Xl, Ωlci)
          + It(cj, ci) × N0(Xl-1, Ωl-1cj) × Λ(ci)
      end
    end
  end
end
Step 4 :
  N1(X) :=  $\sum_{i=1}^M N_1(X_L, \Omega_L^{c_i}) \times I_t(c_i, c_e)$ 

```

図 3: 距離 1 の文の数を計算するアルゴリズム




図 4: bigram,trigram を用いた文認識における単語認識率と文認識率の関係(論説文 136 文)