

8. IBM Model-1 の式の説明

内山将夫@NICT
mutiyama@nict.go.jp

IBM-Model の式の説明のまえに

Q:

何のために確率モデルを利用するか

A:

- 単語対応の確率や
- 単語対応自体を求めるため

単語対応の確率：

「お金」は「cash」と「money」のどちらに訳されることが多いか？

単語対応自体を求めるため：

「今日」「は」「良い」「天気」「だ」と「It」「is」「fine」
「today」では、「今日」はどの単語に対応するか？

単語対応自体を求めるにはどうするか

条件：

英文 e と仏文 f が与えられていて、単語対応 a について、 $P(f, a|e)$ が計算できるとする

求めるもの \hat{a} ：

$$\hat{a} = \arg \max_a P(f, a|e)$$

\hat{a} は、 $P(f, a|e)$ を最大化するアラインメントである。これは最も確率が高いアラインメントである。

→ アラインメントの確率をモデル化することにより、そのモデルの下での最適アラインメントを求めることができる。

単語対応の確率を求めにはどうするか

- 求めたいパラメタを θ として，明示的に式に導入すると

$$P(\mathbf{f}|\mathbf{e}, \theta)$$

により， θ をパラメタとしたときの \mathbf{f} の確率がわかる

- パラレルコーパスを $\mathbf{d} = \{\langle \mathbf{f}, \mathbf{e} \rangle\}$ とすると

$$L(\theta|\mathbf{d}) = \log \prod_{\langle \mathbf{f}, \mathbf{e} \rangle \in \mathbf{d}} P(\mathbf{f}|\mathbf{e}, \theta)$$

によりパラメタ θ の下での，コーパス全体での \mathbf{f} の確率がわかる．このとき

$$\hat{\theta} = \arg \max_{\theta} L(\theta|\mathbf{d})$$

なる $\hat{\theta}$ をみつけると，コーパスを最尤で生成する θ が求まる．

ここまでのまとめ

確率でモデル化することにより

- 単語対応 (アラインメント) が計算できる
- 単語対応確率等のパラメタが計算できる

→ 大きな利点

難しいところ

- モデルの正当性の評価が難しい
- 数式で色々なことを表現しないといけないので、あまり複雑なことは表現できない
- モデルの良さは、実際にデータに適用してみないとわからない
- 良いアイディアと思っても上手くいくかはわからない

IBM model-1 の式展開

$$P(\mathbf{f}, \mathbf{a}|\mathbf{e}) = P(m|\mathbf{e}) \prod_{j=1}^m P(a_j|a_1^{j-1}, f_1^{j-1}, m, \mathbf{e}) \\ P(f_j|a_1^j, f_1^{j-1}, m, \mathbf{e}) \quad (1)$$

$$P(m|\mathbf{e}) = \text{仏文の長さ (単語数) が } m \text{ である確率} \\ = \text{ある定数 } \epsilon$$

$$P(a_j|a_1^{j-1}, f_1^{j-1}, m, \mathbf{e}) = j \text{ 番目の仏単語がつながるのが} \\ a_j \text{ 番目の英単語の確率} \\ = \text{どの場所にも同確率} \\ = \frac{1}{l+1}$$

$$P(f_j|a_1^j, f_1^{j-1}, m, \mathbf{e}) \\ = j \text{ 番目の仏単語が } f_j \text{ の確率} \\ = f_j \text{ と } e_{a_j} \text{ のみで決まる} \\ = t(f_j|e_{a_j})$$

以上より

$$P(\mathbf{f}, \mathbf{a}|\mathbf{e}) = \frac{\epsilon}{(l+1)^m} \prod_{j=1}^m t(f_j|e_{a_j}) \quad (2)$$

アラインメント \mathbf{a} について和をとる

$$\begin{aligned}
 P(\mathbf{f}|\mathbf{e}) &= \sum_{\mathbf{a}} P(\mathbf{f}, \mathbf{a}|\mathbf{e}) \\
 &= \sum_{\mathbf{a}} \frac{\epsilon}{(l+1)^m} \prod_{j=1}^m t(f_j|e_{a_j}) \\
 &= \frac{\epsilon}{(l+1)^m} \sum_{\mathbf{a}} \prod_{j=1}^m t(f_j|e_{a_j}) \\
 &= \frac{\epsilon}{(l+1)^m} \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \prod_{j=1}^m t(f_j|e_{a_j}) \quad (3)
 \end{aligned}$$

$\mathbf{a} = a_1 \dots a_m$ における a_j は仏語 f_j が英単語 e_{a_j} に継がることを示す．また， $\mathbf{e} = e_1 \dots e_l$ で，かつ， $e_0 = \text{NULL}$ である．そのため， $0 \leq a_j \leq l$ である．更に， $1 \leq j \leq m$ なので，上式のように変形される．

パラメタ推定

3式において推定すべきパラメタは $t(f|e)$ のみである．
これには前述のように，

$$\max P(\mathbf{f}|\mathbf{e})$$

となる $t(\cdot)$ を推定すれば良い．
制約として，各英単語 e について

$$\sum_f t(f|e) = 1$$

である．つまり，各英単語 e について，それに対応する f の確率の和は1 である．

ラグランジェの未定乗数法により極値を求める

3式と制約より

$$h(t, \lambda) = \frac{\epsilon}{(l+1)^m} \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \prod_{j=1}^m t(f_j|e_{a_j}) - \sum_e \lambda_e (\sum_f t(f|e) - 1) \quad (4)$$

第2項が制約部分であり，これは λ_e で偏微分をすることにより，

$$\frac{\partial h}{\partial \lambda_e} = -(\sum_f t(f|e) - 1) = 0 \quad (5)$$

となる．つまり， λ_e による偏微分の結果が0であることにより，極値におけるパラメタ値が制約を満すようになる．

一方， $t(f|e)$ による偏微分においては，4式の第2項は，

$$\frac{\partial}{\partial t(f|e)} - \sum_e \lambda_e (\sum_f t(f|e) - 1) = -\lambda_e \quad (6)$$

4式の第1項は，まず，

$$\prod_{j=1}^m t(f_j|e_{a_j})$$

を偏微分する．

$$\begin{aligned}
& \frac{\partial}{\partial t(f|e)} \prod_{j=1}^m t(f_j|e_{a_j}) \\
&= \left(\prod_{\substack{1 \leq k \leq m \\ f_k \neq f \vee e_{a_k} \neq e}} t(f_k|e_{a_k}) \right) \frac{\partial}{\partial t(f|e)} t(f|e)^{\sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j})} \\
&= \left(\prod_{\substack{1 \leq k \leq m \\ f_k \neq f \vee e_{a_k} \neq e}} t(f_k|e_{a_k}) \right) n(e, f) t(f|e)^{n(e, f)-1} \\
&= n(e, f) t(f|e)^{-1} \left(\prod_{\substack{1 \leq k \leq m \\ f_k \neq f \vee e_{a_k} \neq e}} t(f_k|e_{a_k}) \right) t(f|e)^{n(e, f)} \\
&= n(e, f) t(f|e)^{-1} \prod_{1 \leq k \leq m} t(f_k|e_{a_k}) \tag{7}
\end{aligned}$$

ただし ,

$$\begin{aligned}
n(e, f) &= \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \\
&= \text{仏単語が } f_j \text{ で英単語が } a_j \text{ の単語対応の数}
\end{aligned}$$

- 1行目では , $t(f|e)$ の項を取り出す
- 2行目では , $t(f|e)$ で偏微分する
- 3,4 行目では , $t(f|e)^{-1}$ を括り出すことにより , $\prod_{1 \leq k \leq m} t(f_k|e_{a_k})$ を再導入する

以上より ,

$$\begin{aligned}
& \frac{\partial}{\partial t(f|e)} h(t, \lambda) \\
&= \frac{\epsilon}{(l+1)^m} \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \left(\sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \right) t(f|e)^{-1} \\
& \quad \prod_{1 \leq k \leq m} t(f_k|e_{a_k}) - \lambda_e \tag{8}
\end{aligned}$$

これを0とおくと

$$\begin{aligned}
t(f|e) &= \lambda_e^{-1} \frac{\epsilon}{(l+1)^m} \\
& \times \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \left(\sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \right) \prod_{1 \leq k \leq m} t(f_k|e_{a_k}) \tag{9}
\end{aligned}$$

まず， λ_e について説明すると，これは4式において， $\sum_f t(f|e) = 1$ となるように導入した変数である．この制約を満すには， $t(f|e) = \lambda_e^{-1} A(f|e)$ としたとき， $\lambda_e = \sum_f A(f|e)$ とすると， $\sum_f t(f|e) = 1$ となる．つまり， λ_e は，単なる正規化定数である．

これまでのまとめ

- 9式により, $t(f|e)$ を表現した
- この式を利用すると $t(f|e)$ が求まると思われる
- しかし右辺にも $t(\cdot)$ がでてくる

EM法により $t(\cdot)$ を求める

1. まず $t(\cdot)$ に適当な初期値を定める
2. 次に, その値を利用して, 9式により $t(\cdot)$ を計算する
3. 2を繰り返す

このようにして, $t(e|f)$ を求める道筋が整った. 次は, 9式を簡単化していく.

9式の再掲

$$t(f|e) = \lambda_e^{-1} \frac{\epsilon}{(l+1)^m} \times \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \left(\sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \right) \prod_{1 \leq k \leq m} t(f_k | e_{a_k})$$

3式の再掲

$$P(\mathbf{f}|\mathbf{e}) = \sum_{\mathbf{a}} P(\mathbf{f}, \mathbf{a}|\mathbf{e}) = \frac{\epsilon}{(l+1)^m} \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \prod_{j=1}^m t(f_j | e_{a_j})$$

これらより

$$t(f|e) = \lambda_e^{-1} \sum_{\mathbf{a}} P(\mathbf{f}, \mathbf{a}|\mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \quad (10)$$

これを更に概念的に簡単化するために，

$$C(f|e; \mathbf{f}, \mathbf{e}) = \sum_{\mathbf{a}} P(\mathbf{a}|\mathbf{f}, \mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \quad (11)$$

を定義する．

この式の $\sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j})$ は，アラインメント \mathbf{a} において f と e が継がっている回数である．また， $P(\mathbf{a}|\mathbf{f}, \mathbf{e})$ は，アラインメント \mathbf{a} の確率である．よって， $C(f|e; \mathbf{f}, \mathbf{e})$ は， f と e が対応する回数の期待値である．

これから確認するように， $t(f|e)$ は， f と e の対応の期待度数 $C(f|e, \mathbf{f}, \mathbf{e})$ を利用した割合により表現される．

$$\begin{aligned}
t(f|e) &= \lambda_e^{-1} \sum_{\mathbf{a}} P(\mathbf{f}, \mathbf{a}|\mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \\
&= \lambda_e^{-1} \sum_{\mathbf{a}} P(\mathbf{f}|\mathbf{e}) P(\mathbf{a}|\mathbf{f}, \mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \\
&= \lambda_e^{-1} P(\mathbf{f}|\mathbf{e}) \sum_{\mathbf{a}} P(\mathbf{a}|\mathbf{f}, \mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \\
&= \lambda_e^{-1} P(\mathbf{f}|\mathbf{e}) C(f|e; \mathbf{f}, \mathbf{e}) \\
&= \lambda'_e{}^{-1} C(f|e; \mathbf{f}, \mathbf{e}) \tag{12}
\end{aligned}$$

$\lambda'_e = \lambda_e P(\mathbf{f}|\mathbf{e})^{-1}$ は正規化定数 . $\lambda'_e = \sum_f C(f|e; \mathbf{f}, \mathbf{e})$ とすれば , $\sum_f t(f|e) = 1$ となる .

上記は , 英文 \mathbf{e} と仏文 \mathbf{f} が一文だけしかない場合である . コーパス全体では , s 番目の対訳文を $\mathbf{e}^{(s)}$ と $\mathbf{f}^{(s)}$ で表すと

$$t(f|e) = \lambda'_e{}^{-1} \sum_s C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)})$$

である . これは , 期待度数をコーパス全体で測定している .

これまでのまとめ

$$t(f|e) = \lambda'_e{}^{-1} \sum_s C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)}) \quad (13)$$

$$\lambda'_e = \sum_f \sum_s C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)}) \quad (14)$$

$$C(f|e; \mathbf{f}, \mathbf{e}) = \sum_{\mathbf{a}} P(\mathbf{a}|\mathbf{f}, \mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \quad (15)$$

上式を利用した推定アルゴリズム

1. 全ての f と e について , $t(f|e)$ の初期値を選ぶ .
2. コーパス中の文 s について $C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)})$ を計算する .
3. 各 e について , λ'_e を計算する
4. 各 f について , $t(f|e)$ を計算する
5. goto 2 or exit

残された問題

$$\begin{aligned} C(f|e; \mathbf{f}, \mathbf{e}) &= \sum_{\mathbf{a}} P(\mathbf{a}|\mathbf{f}, \mathbf{e}) \sum_{j=1}^m \delta(f, f_j) \delta(e, e_{a_j}) \\ &= \lambda_e P(\mathbf{f}|\mathbf{e})^{-1} t(f|e) \quad (\text{式12参照}) \end{aligned} \quad (16)$$

をどう計算するか？

4式に戻ると

$$h(t, \lambda) = \frac{\epsilon}{(l+1)^m} \sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \prod_{j=1}^m t(f_j|e_{a_j}) - \sum_e \lambda_e (\sum_f t(f|e) - 1)$$

下線の部分で $(l+1)^m m$ 回の計算が必要になる．この部分を簡単化する必要がある．

$$\sum_{a_1=0}^l \cdots \sum_{a_m=0}^l \prod_{j=1}^m t(f_j|e_{a_j}) = \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i)$$

$(l+1)^m m$ 回の計算量が $m(l+1)$ に減少した .

例により , この変形の正しさを確認する .

$m=3, l=1$ のとき , $t(f_j|e_i) = t_{ji}$ として ,

$$\begin{aligned} \text{左辺} &= \sum_{a_1=0}^1 \sum_{a_2=0}^1 \sum_{a_3=0}^1 \prod_{j=1}^3 t(f_j|e_{a_j}) \\ &= t_{10}t_{20}t_{30} + t_{11}t_{20}t_{30} + \cdots + t_{11}t_{21}t_{30} + t_{11}t_{21}t_{31} \end{aligned}$$

$$\begin{aligned} \text{右辺} &= \prod_{j=1}^3 \sum_{i=0}^1 t(f_j|e_i) \\ &= (t_{10} + t_{11})(t_{20} + t_{21})(t_{30} + t_{31}) \end{aligned}$$

4式を簡単化する

$$h(t, \lambda) = \frac{\epsilon}{(l+1)^m} \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i) - \sum_e \lambda_e (\sum_f t(f|e) - 1)$$

第2項の $t(f|e)$ による偏微分は $-\lambda_e$.

$$n_f = \sum_{j=1}^m \delta(f, f_j) = (f = f_j) \text{ なる } f_j \text{ の数}$$

$$n_e = \sum_{i=0}^l \delta(e, e_i) = (e = e_i) \text{ なる } e_i \text{ の数}$$

とすると

$$\begin{aligned} & \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i) \\ &= \left(\prod_{\substack{1 \leq j \leq m \\ f_j \neq f}} \sum_{i=0}^l t(f_j|e_i) \right) \left(\sum_{i=0}^l t(f|e_i) \right)^{n_f} \\ &= \left(\prod_{\substack{1 \leq j \leq m \\ f_j \neq f}} \sum_{i=0}^l t(f_j|e_i) \right) \left(\sum_{\substack{0 \leq i \leq l \\ e_i \neq e}} t(f|e_i) + n_e t(f|e) \right)^{n_f} \quad (17) \end{aligned}$$

だから

$$\begin{aligned} & \frac{\partial \text{第2項}}{\partial t(f|e)} \\ &= n_f n_e \left(\sum_{\substack{0 \leq i \leq l \\ e_i \neq e}} t(f|e_i) + n_e t(f|e) \right)^{n_f-1} \\ &= n_f n_e \left(\sum_{0 \leq i \leq l} t(f|e_i) \right)^{n_f-1} \\ &= \frac{n_f n_e}{\sum_{0 \leq i \leq l} t(f|e_i)} \left(\sum_{0 \leq i \leq l} t(f|e_i) \right)^{n_f} \quad (18) \end{aligned}$$

以上より ,

$$\frac{\partial}{\partial t(f|e)} \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i) = \frac{n_f n_e}{\sum_{0 \leq i \leq l} t(f|e_i)} \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i) \quad (19)$$

よって ,

$$\begin{aligned} & \frac{\partial h(t, \lambda)}{\partial t(f|e)} \\ &= \frac{n_f n_e}{\sum_{i=0}^l t(f|e_i)} \frac{\epsilon}{(l+1)^m} \prod_{j=1}^m \sum_{i=0}^l t(f_j|e_i) - \lambda_e \\ &= \frac{n_f n_e}{\sum_{i=0}^l t(f|e_i)} P(\mathbf{f}|\mathbf{e}) - \lambda_e \end{aligned} \quad (20)$$

よって , 極値では $\frac{\partial h(t, \lambda)}{\partial t(f|e)} = 0$ より

$$\lambda_e P(\mathbf{f}|\mathbf{e})^{-1} = \frac{n_f n_e}{\sum_{i=0}^l t(f|e_i)}$$

よって , 16 式より

$$\begin{aligned} & C(f|e; \mathbf{f}, \mathbf{e}) \\ &= \lambda_e P(\mathbf{f}|\mathbf{e})^{-1} t(f|e) \\ &= \frac{t(f|e)}{\sum_{i=0}^l t(f|e_i)} n_f n_e \end{aligned} \quad (21)$$

ここで , $\frac{t(f|e)}{\sum_{i=0}^l t(f|e_i)}$ は , f と e という対応に与えられる重みであり , $n_f n_e$ は , そのような対応の数である .

核となる式

$$C(f|e; \mathbf{f}, \mathbf{e}) = \frac{t(f|e)}{\sum_{i=0}^l t(f|e_i)} n_f n_e \quad (22)$$

$$\lambda_e = \sum_f \sum_s C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)}) \quad (23)$$

$$t(f|e) = \lambda_e^{-1} \sum_s C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)}) \quad (24)$$

$t(\cdot)$ 推定のアルゴリズム

1. $t(f|e)$ の初期値を設定する
2. 各文 s について $C(f|e; \mathbf{f}^{(s)}, \mathbf{e}^{(s)})$ を計算する .
3. 各 e について , λ_e を計算する .
4. 各 f について , $t(f|e)$ を計算する .
5. goto 2 or exit.

課題

Peter F. Brown, Stephen A. Della Pietra, Vincent J. Della Pietra, and Robert L. Mercer. (1993) The Mathematics of Statistical Machine Translation: Parameter Estimation.
を読んでみる .