

11-2007

1.

$$1.1 \quad P(F, A | E) = \prod_{j=1}^m P(f_j, a_j | f_1, a_1, E)$$

$$= \prod_{j=1}^m P(a_j | a_1, f_1, E) \cdot P(f_j | f_1, a_1, E)$$

1.2 Quand on jointe une phrase F et son alignement A

- on cherche à quel mot de E on se connecte la position dans F position dans E connecte la position dans le phrase F en sachant E
- on choisit quel mot de F connaît E et la position a_1 etc

2

2-1

$$P(a_j | a_1, f_1, E) = \frac{1}{n+1}$$

so proba. uniforme
she depend que de n
o ind. des a_j par E, F

$$P(f_j | a_1, f_1, E) = P(f_j | e_{a_j})$$

f_j ne depend que
de la position a_j et du
mot e_{a_j} par du phrase.

2.2

2

$$P(F, A | \varepsilon) = \frac{1}{(n+1)^m} \prod_{j=1}^m P(p_j | e_{q_j})$$

2.3

$$\begin{aligned} P(F | E) &= \sum_A P(F, A | \varepsilon) \\ &= \frac{1}{(n+1)^m} \sum_{a_1=0}^m \dots \sum_{a_m=0}^m \prod_{j=1}^m P(p_j | e_{q_j}) \end{aligned}$$

3

3.1 Mélange de densités / HAN

3.2 Non \rightarrow équation complexe

3.3 $Q(\theta, \hat{\theta})$ est l'espérance de la log vraisemblance $\log P_{\theta}(F, A | \varepsilon)$ pour la distribution de A

3.4

$$\begin{aligned} Q(\theta, \hat{\theta}) &= \mathbb{E} \sum_A (\log P_{\theta}(F, A | \varepsilon)) P_{\hat{\theta}}(A | F, \varepsilon) \\ &= \sum_A \left(\log \frac{1}{(n+1)^m} + \log \prod_{j=1}^m \frac{P(p_j | e_{q_j})}{\theta_j} \right) P_{\hat{\theta}}(A | F, \varepsilon) \end{aligned}$$

$$Q(\theta, \hat{\theta}) = \sum_A \left(\log \prod_{j=1}^m \frac{P(p_j | e_{q_j})}{\theta_j} \right) P_{\hat{\theta}}(A | F, \varepsilon) + \sum_A \log \frac{1}{(n+1)^m} P_{\hat{\theta}}(A | F, \varepsilon)$$

3.5

3

$$L = Q(\theta, \bar{\theta}) - \sum_e \lambda_e \sum_f (P(f|e) - 1)$$

3.6

$$\begin{aligned} \frac{dL}{dP(f|e)} &= \frac{dQ}{dP(f|e)} - \lambda_e \\ &= \frac{d}{dP(f|e)} \left(\sum_{j=1}^m \sum_{k=1}^n P_{\bar{\theta}}(k|j, F, E) \log P_{\theta}(f_j|e_k) + K \right) - \lambda_e \\ &= \sum_{j=1}^m \sum_{k=1}^n P_{\bar{\theta}}(k|j, F, E) \delta(f, f_j) \delta(e, e_k) \times \frac{1}{P(f_j|e_k)} - \lambda_e \end{aligned}$$

$$\frac{dL}{dP_{\theta}(f|e)} = 0 \Leftrightarrow P_{\theta}(f|e) = \lambda_e^{-1} \sum_{j=1}^m \sum_{k=1}^n P_{\bar{\theta}}(k|j, F, E) \delta(f, f_j) \delta(e, e_k)$$

3.87

$$P_{\theta}(f|e) = \lambda_e^{-1} \sum_{j=1}^m \sum_{k=1}^n \frac{P_{\theta}(f_j|e_k)}{\sum_i P_{\theta}(f_i|e_i)} \times d(f, f_j) d(e, e_k)$$

$$\textcircled{1} \left| P_{\theta}(f|e) = \lambda_e^{-1} \frac{P_{\theta}(f|e)}{\sum_i P_{\theta}(f_i|e_i)} \sum_{j=1}^m d(f, f_j) \sum_{k=1}^n d(e, e_k) \right|$$

3.88 Algorithm

- initialize $L_i P_{\theta}(f|e) \quad \forall f \neq e$

- $\left[\begin{array}{l} \leftarrow P_{\theta}^{\leftarrow}(k|j, F|e) = \frac{P_{\theta}(f_j|e_k)}{\sum_i P_{\theta}(f_i|e_i)} \end{array} \right]_{\text{revis.}} \left. \begin{array}{l} \text{step } \leftarrow \end{array} \right]$

- Π formula 1.

5-

5

5-1 CRF — états discriminatifs vs générique.

→ possibilité de prendre en compte des features arbitraires sur les entrées et les relations entrées/sorties.

→ prise en compte de dépendances long terme.

- proba NU vs proba MAP
- régularisation

5-2

- features arbitraires
- dep. long terme
- dep. entrées/sorties

5-3

- CRF prend en compte les dépendances entrées/sorties
- régularisation pour éviter overfitting

5-4

h_k : features

λ_k : poids

Z : normalisation

5-5

données : phrases alignées

critère : MAP régularisé

algo : BFGS - gradient