


TA estadística



Modelos de la TAE

- El objetivo del modelo de lenguaje es asignar probabilidades altas a frases gramaticales en el LM
 - Básicamente prestado del área del reconocimiento del habla
 - Luego, veremos estos modelos en más detalle
- El modelo de traducción relaciona frases en LO a frases en LM
 - Describe cómo se originó f a partir de e
 - Para esto necesita "estudiar" relaciones previas, llamadas **alineamientos** de textos
- El proceso de descodificación implementa algún algoritmo de búsqueda que permita maximizar el producto de probabilidades
 - Algunos algoritmos usados son A^* , Viterbi para HMMs, stack decoding, beam search...

Alineamiento de textos (1/5)

- Dado un corpus paralelo bilingüe, **alinear** frases consiste en **conectar** cada frase en L1 a su equivalente semántico en L2
 - Frases de largo 1 = palabras o *unigramas*, de largo 2 = *bigramas*, largo n = *n-gramas*
- Además de su uso en TA, los textos alineados se usan para derivar diccionarios bilingües, BDs terminológicas, ...
- Varias formas de alinear textos, por ej
 - Basadas en el largo de las frases medido en caracteres o palabras [Church&Gale '93; Dagan et al '93, Chang '93]
 - Basada en lexicones: usan la categoría semántica de palabras, POS tags, sinonimia [Ker et al '97; Wang '99]


Alineamiento de textos (2/5)

LO = Español	LM = Italiano
<seg id="1"> La Bolsa de Praga terminó con menos puntos al final de la jornada </seg>	<seg id="1"> La Borsa di Praga alla chiusura del mercato ha avuto un crollo negativo.</seg>
<seg id="5"> Sin embargo , todavía no está ganado. </seg>	<seg id="5"> Ma non è ancora detta. </seg>
<seg id="9"> Según algunas fuentes, la votación sobre el plan se podría realizar en el Senado no antes del miércoles. </seg>	<seg id="9"> Al Senato, secondo alcune fonti, si potrebbe votare riguardo al piano probabilmente non prima di Lunedì. </seg>
<seg id="12"> Paulson: El plan debe ser eficaz </seg>	<seg id="12"> Paulson: il Piano dev'essere efficace </seg>

- Extracto corpus paralelo multilingüe Europarl [Koehn 005] [<http://www.statmt.org/europarl/>]


Alineamiento de textos (3/5)

- Dado el corpus anterior, cuáles son los posibles alineamientos?



Alineamiento de textos (4/5)

- Para formalizar la noción gráfica de alineamientos, se introduce una **función** $a: i \rightarrow j$ que mapea la palabra del LM en posición i a la palabra en LO en posición j
 - $A(e,f)$ = conjunto de alineamientos de $(f|e) = U\{t_i \rightarrow s_j\}$
- Si cada palabra se conecta a una sola (ej 1 slide anterior), entonces $A = \{1 \rightarrow 1, 2 \rightarrow 2, 3 \rightarrow 3, \dots\}$
- En cambio en el segundo ejemplo tenemos:



Alineamiento de textos (5/5)

- El ejemplo anterior muestra algunos fenómenos como reordenamientos, alineamientos múltiples (1-n) y alineamientos 1-0 (no conectados a nada)
- También se pueden dar
 - n-n: varias palabras origen a varias palabras meta; ej expresiones idiomáticas
 - 0-1: en LM debe aparecer una palabra no derivada explícitamente de la frase origen; ej men cook → los hombres cocinan
 - n-1: una palabra origen genera varias en LM; ej however → sin embargo
- Además de la dificultad intrínseca de alinear textos, pueden haber factores relacionados a la colección del corpus
 - Ej anterior "no antes del miércoles" → "non prima di Lunedì"
- O a la utilización del corpus (ej plan → Piano o piano ?)

Modelos IBM [Brown et al '93]

- Los modelos de traducción IBM 1 al 5 indican cómo computar $P(f|e)$ en términos de $A(e,f)$

$$P(f|e) = \sum_{a \in A} P(f, a|e)$$
- Donde $P(f, a|e) = P(m|e)P(a|m, e)P(f|a, m, e)$
- Cada modelo presenta una forma distinta de computar $P(f|e)$ como la prob conjunta $P(F=f, A=a, E=e)$

Modelo 1 de IBM

- Es el mas simple de los 5
- No considera el orden de las palabras, toma cada frase como una bolsa de palabras
- No modela alineamientos 1-n, sólo 1-1
- Reserva la posición 0 de e por si hay que insertar una palabra no generada de f (1-Null)
- Con estas restricciones es un modelo fácil de implementar y eficiente de computar
- Útil para inicializar parámetros que serán utilizados por otros modelos

Modelo 1 de IBM

- Las probabilidades para este modelo son:

$$P(f, a|e) = P(m|e)P(a|m, e)P(f|a, m, e)$$

Cuando genero f y a a partir de e (de largo l) puedo elegir el largo de f (m) con lo que conozco de e

Modela dónde conectar una posición de f de acuerdo al conocimiento adquirido sobre e y el largo de f

Modela la elección de palabras en f de acuerdo al conocimiento adquirido sobre e , el largo de f y la posición en e a la que se conecta la posición de f

Modelo 1 de IBM

- Las probabilidades para este modelo son:

$$P(f, a|e) = P(m|e)P(a|m, e)P(f|a, m, e)$$

donde $P(m|e) = \epsilon(m/l)$ → ditrib de prob de largo de las cadenas e de largo l se genera de f de largo m

Modelo 1 de IBM

- Las probabilidades para este modelo son:

$$P(f, a|e) = P(m|e)P(a|m, e)P(f|a, m, e)$$

donde $P(m|e) = \epsilon(m/l)$

$$P(a|m, e) = (l+1)^{-m}$$

→ Como este modelo toma todos los alineamientos igualmente válidos, cada una de las m posibles conexiones tiene peso $1/(l+1)$

Modelo 1 de IBM

- Las probabilidades para este modelo son:

$$P(f, a | e) = P(m | e)P(a | m, e)P(f | a, m, e)$$

donde $P(m | e) = \varepsilon(m/l)$

$$P(a | m, e) = (l + 1)^{-m}$$

$$P(f | a, m, e) = \prod_{j=1}^m t(f_j | e_{a_j})$$

Probabilidad de traducir
La palabra f_j como e_j , dado el
alineamiento a_j

Modelo 1 de IBM

- Las probabilidades para este modelo son:

$$P(f, a | e) = P(m | e)P(a | m, e)P(f | a, m, e)$$

donde $P(m | e) = \varepsilon(m/l)$

$$P(a | m, e) = (l + 1)^{-m}$$

$$P(f | a, m, e) = \prod_{j=1}^m t(f_j | e_{a_j})$$

Ecuación final

$$P(f | e) = \sum_{a \in A} \frac{\varepsilon}{(l + 1)^m} \prod_{j=1}^m P(f_j | e_{a_j})$$

Modelo 1 de IBM

- Para este modelos los parámetros libres que se estiman durante el proceso de *entrenamiento* son:

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


- Entrenamiento = inicialización parámetros + EM
 - EM = expectation-maximization

Aprendizaje no supervisado (EM)

- Queremos buscar el EMV de las probabilidades sobre el conjunto de datos de entrenamiento
 - En este caso las variables latentes u ocultas son alineamientos
- Algoritmo Expectation-Maximization (EM)
 - E-Step: predecir parámetros de acuerdo a los valores actuales
 - M-Step: re-estimar a partir de las predicciones
 - Iterar: con suerte converge a los EMV de los parámetros o a un máximo local
- Este proceso se considera la decodificación

16


EM algorithm



- Initial step: all alignments equally likely
- Model learns that, e.g., *la* is often aligned with *the*

Slide from Koehn 2008

EM algorithm



- After one iteration
- Alignments, e.g., between *la* and *the* are more likely

Slide from Koehn 2008

EM algorithm

... la maison ... la maison bleu ... la fleur ...

... the house ... the blue house ... the flower ...

- After another iteration
- It becomes apparent that alignments, e.g., between *fleur* and *flower* are more likely (**pigeon hole principle**)

Slide from Koehn 2008

EM algorithm

... la maison ... la maison bleu ... la fleur ...

... the house ... the blue house ... the flower ...

- Convergence
- Inherent hidden structure revealed by EM

Slide from Koehn 2008

EM algorithm

... la maison ... la maison bleu ... la fleur ...

... the house ... the blue house ... the flower ...

$p(la|the) = 0.453$
 $p(le|the) = 0.334$
 $p(maison|house) = 0.876$
 $p(bleu|blue) = 0.563$
 ...

- Parameter estimation from the aligned corpus

Slide from Koehn 2008

IBM Model 1 and EM

- EM Algorithm consists of two steps
 - **Expectation-Step:** Apply model to the data
 - parts of the model are hidden (here: alignments)
 - using the model, assign probabilities to possible values
 - **Maximization-Step:** Estimate model from data
 - take assign values as fact
 - collect counts (weighted by probabilities)
 - estimate model from counts
- Iterate these steps until **convergence**

Probabilidad de alineamientos
 Count de (f|e) = esperanza #de veces que e se conecte a f

Slide from Koehn 2008

IBM Model 1 and EM

- **Probabilities**

$$p(the|la) = 0.7 \quad p(house|la) = 0.05$$

$$p(the|maison) = 0.1 \quad p(house|maison) = 0.8$$
- **Alignments**

$$p(e, a|f) = 0.56 \quad p(e, a|f) = 0.035 \quad p(e, a|f) = 0.08 \quad p(e, a|f) = 0.005$$

$$p(a|e, f) = 0.824 \quad p(a|e, f) = 0.052 \quad p(a|e, f) = 0.118 \quad p(a|e, f) = 0.007$$
- **Counts**

$$c(the|la) = 0.824 + 0.052 \quad c(house|la) = 0.052 + 0.007$$

$$c(the|maison) = 0.118 + 0.007 \quad c(house|maison) = 0.824 + 0.118$$

Slide from Koehn 2008

IBM Model 1 and EM: Pseudocode

```

initialize t(e|f) uniformly
do until convergence
  set count(e|f) to 0 for all e,f
  set total(f) to 0 for all f
  for all sentence pairs (e_s, f_s)
    for all words e in e_s
      total_s(e) = 0
      for all words f in f_s
        total_s(e) += t(e|f)
    for all words e in e_s
      for all words f in f_s
        count(e|f) += t(e|f) / total_s(e)
        total(f) += t(e|f) / total_s(e)
  for all f
    for all e
      t(e|f) = count(e|f) / total(f)
  
```

Slide from Koehn 2008

Modelo 2

- Modelo 2 incorpora concepto de **reordenamiento absoluto** de palabras
 - La probabilidad de una conexión **a** depende de la posición en e, f y el largo de ambas
 - Es decir, depende del orden de las palabras en e y f
 - Son alineamientos más generales que el M 1

$$P(a | m, e) = (l + 1)^{-m} \rightarrow P(a | m, e) = a(a | j, m, l)$$

- EM es calculado exactamente excepto que hay varios máximos locales
- Como Modelo 1 es caso particular de Modelo 2 → se usa para inicializar EM

Modelo 3

- Incorpora **fertilidad** y **distorsión**
 - Fertilidad: probabilidad de que una palabra en e se conecte a n palabras de f
 - Distorsión: prob que una palabra de e en posición i se conecte a una palabra en posición j (dado el largo de e y f)
 - Posiciones absolutas
- Trata conexiones 1-NUL con una distrib de proba uniforme
 - Potencialmente todas las palabras de f podrían no estar conectadas a alguna palabra en e
- Iterar sobre todos los alineamientos existentes es imposible
 - Técnica para calcular los **a** más probables → pegging


Pegging – Modelo 3

- Primero se obtiene un conjunto de mejores **a** entrenando Modelo 1 y luego se ajustan con Modelo 3 haciendo pequeños cambios
 - Movimiento: se cambia una conexión (j,i) a (j,i')
 - Swap: se intercambia un par (j,i)-(j',i') por (j,i')-(j',i)
 - El conj de **a** resultante se llama vecindad (neighborhood)
- Si uno de estos cambios aumenta la prob de traducción se agrega al conjunto de alineamientos

Deficiencia del modelo

- El principal problema es que asigna probabilidades a frases imposibles de generar
 - Por ejemplo **is possible**
- Esto ocurre por las probabilidades de distorsión que generan distintas palabras en la misma posición
- Sin embargo, podría ser posible filtrarlas mas adelante

IBM Model 4



Slide from Koehn 2008

Modelos 1–5

- Modelo 1: bolsa de palabras
 - Algoritmo EM calculado exactamente (no aproximado)
 - Máximos locales únicos
- Modelo 2: alineamientos generales
 - Como en modelo 1 EM calculado exactamente
 - Agrega reordenamientos absolutos
- Modelo 3: agrega fertilidad: $n(k | e)$
 - De este en adelante solo aproximaciones de EM
 - Cuenta solo vecinos (Model 3–5)
 - Es deficiente (Model 3–4)
- Modelo 4: distorsion relativa $d(k|e)$, clases de palabras
- Modelo 5: arregla el problema de la deficiencia

[Limitaciones de modelos IBM]

- Solo consideran mapeos de palabras 1-N
- Toda la información sintáctica se limita a clases de palabras y distorsión
- No es posible hacer reordenamientos de larga distancia
- La gramaticalidad (fluency) de las traducciones depende exclusivamente del modelo de lenguaje usado