

El menú de hoy

- Modelos por frases
 - Sintácticos [Yamada 01]
 - Probabilidad conjunta [Marcu 02]
 - Basados en noisy-channel [Koehn 03]
 - Alignment template [Och 03]
 - Factored models [Koehn 07]
- Estimación de parámetros (MERT)
- Alineamiento de frases
- Práctico 4

Modelos de traducción


- Los modelos de traducción nacen en IBM y son la base de la TA pero tienen algunas limitaciones
 - Principalmente que solo modelan alineamientos 1-N de LM a LO
 - Es decir en la traducción EN-ES varias palabras en inglés pueden conectarse a una en español pero no al revés
 - Alineamientos más generales N-M son difíciles de modelar dados los parámetros de estos modelos (n,d,p,t)
- ¿Cuáles son las consecuencias de estas restricciones? → textos mal o no traducidos

Ejemplos

- DE-ES *Zahnarzttermin* = cita/turno con el dentista
- EN-FR *make with breadcrumbs* = gratiner
- DE-EN *Kindergarten* = kindergarten pero EN-ES *kindergarten* = jardín de infantes
- Dependiendo de los pares utilizados, con IBM estos pasajes podrían o no estar bien modelados

Modelos por frases

- Modelos más generales con mejor performance, capturan el contexto local de las palabras
 - Frases = unidades mayores a una palabra, no relacionado con estructura sintáctica de una oración
- Intuitivamente estos modelos funcionan así:



El menú de hoy

- Modelos por frases
 - Sintácticos [Yamada 01]
 - Probabilidad conjunta [Marcu 02]
 - Basados en noisy-channel [Koehn 03]
 - Alignment template [Och 03]
 - Factored models [Koehn 07]
- Estimación de parámetros (MERT)
- Alineamiento de frases
- Práctico 4

Diversidad de modelos

- Objetivo de un modelo de traducción es crear una tabla de traducción (t-table)
 - Usada durante la búsqueda (decoding)
- Existen muchos modelos pero pocos tienen alguna implementación disponible
- Veremos brevemente algunos modelos y con más detalles los que se implementan en Moses
 - Decoder disponible libremente que usaremos en el próximo práctico

Sintácticos

- [Yamada&Knight 2001] proponen modelo sintáctico donde el árbol de parser se modifica para generar oración en LM sintácticos
 - Parecido a los modelos de lenguaje sintácticos de la clase pasada
- Entrenan su modelo sobre un corpus EN-JP y crean tablas de probabilidades para las operaciones sobre los árboles
 - Reordenamiento de nodos (sov eng/zh, svo jp/tr), inserción de nodos a izq o der, traducción

Sintácticos

Ejemplo de tablas generadas

original order	reordered	Preorder
PRP VB1 VB2	PRP VB1 VB2	0.074
PRP VB2 VB1	PRP VB2 VB1	0.723
VB1 PRP VB2	VB1 PRP VB2	0.081
VB1 VB2 PRP	VB1 VB2 PRP	0.037
VB2 PRP VB1	VB2 PRP VB1	0.083
VB2 VB1 PRP	VB2 VB1 PRP	0.021
VB TO	VB TO	0.251
TO VB	TO VB	0.749
TO NN	TO NN	0.107
NN TO	NN TO	0.893
:	:	:

parent	TOP	VB	VB	VB	TO	TO
root	VB	VB	PRP	TO	NN	
FNONE	0.735	0.687	0.344	0.709	0.900	0.800
FNONE	0.004	0.081	0.004	0.030	0.003	0.006
FRight	0.280	0.252	0.652	0.281	0.007	0.104

node	Prn	ad
na	0.219	
ta	0.131	
wo	0.089	
no	0.094	
ni	0.080	
te	0.079	
ga	0.062	
desu	0.007	

E	adpos	hw	i	listenra	music	to
J	desuki 1.000	are 0.952	NULL 0.471	aku 0.333	ongaku 0.900	ni 0.216
		NULL 0.016	watashi 0.111	ki 0.333	naru 0.100	NULL 0.204
		nani 0.005	are 0.055	mi 0.333		to 0.133
		de 0.003	ni 0.021			no 0.046
		shi 0.003	nani 0.020			wo 0.038

Table 1: Model Parameter Tables

Modelos de probabilidad conjunta

- [Marcu&Wong 2002] proponen aprender pares de oraciones (e,f) en vez de aprender cómo e se genera desde f
 - Aprenden directamente de un corpus paralelo
- Idealmente si se aprende la prob conjunta P(e,f) se aprende también P(e|f) y P(f|e)
 - Consistente con modelos IBM pero usando frases
- Algunos problemas son la cantidad exponencial de posibles frases alineadas, el costo computacional
 - Solución: aprender frases de largo <6, probar con DP, ...

Modelo por frases [Koehn 03]

- Usa el canal ruidoso como los modelos IBM
 - Luego en FR-EN, modelamos P(f|e)*P(e) por Bayes
- Cada oración se segmenta en J frases $f_1^J = f_1, \dots, f_J$ con distribución uniforme sobre todos los posibles segmentos
- Cada frase f_i se traduce por una frase e_i
 - ahora la probabilidad de traducción dada por la distribución $\phi(f_i | e_i)$

Modelo por frases [Koehn 03]

- El reordenamiento de frases se modela con la prob de distorsión relativa $d(\text{start}_i, \text{end}_{i-1})$
 - start = posición en origen donde comienza la frase que se traduce por la i -ésima frase destino, análogo para end
 - Formalmente se estima con $\alpha^{|\text{start}_i, \text{end}_{i-1}|}$
- Se introduce un parámetro que calibra la longitud de las traducciones ω (costo)
- Durante el proceso de búsqueda (decoding) se intenta maximizar la ecuación dada por

Modelo por frases [Koehn 03]

$$\begin{aligned} & \arg\max_e P(e|f) \\ & = \arg\max_e P(f|e) * P(e) \\ & = \prod_{i=1}^J \phi(f_i | e_i) \alpha^{|\text{start}_i, \text{end}_{i-1}|} P(e) \omega^{|e|} \end{aligned}$$

Modelos log-linear [Och 2003]

- Una alternativa al canal ruidoso es modelar directamente $P(e|f)$ y encontrar $\operatorname{argmax}_e P(e_1^J, f_1^K)$
- Combinan funciones características $h_i(e_1^J, f_1^K)$ $i=1..M$ que describen distintos aspectos de la traducción (*features*)
 - $\hat{e} = \operatorname{argmax}_e \prod_{i=1}^M \rho_i^{h_i(e|f)}$
 - ρ_i es el peso asignado a cada h_i

Modelos log-linear

- Si elegimos features relativas a los modelos de lenguaje y traducción como $h_1(e,f) = \log_{\rho_1} P(e)$, $h_2(e,f) = \log_{\rho_2} P(f|e)$
- Podemos reescribir la ecuación anterior:

$$\hat{e} = \operatorname{argmax}_e \prod_{i=1}^2 \rho_i^{h_i(e|f)}$$

$$= \operatorname{argmax}_e \rho_1^{h_1(e|f)} \rho_2^{h_2(e|f)}$$

$$= \operatorname{argmax}_e P(e) * P(f|e)$$
- modelos log-linear son una generalización del modelo anterior (noisy-channel)

Log-linear phrase-based

- La ventaja de los modelos log-linear es que pueden asignarle pesos a sus componentes
 - Ej modelo de lenguaje o al de traducción
- Otra ventaja es la simplificación que permiten al tomar log a ambos lados

$$\log P(e|f) = \log \prod_{i=1}^M \rho_i^{h_i(e|f)}$$

$$= \sum_{i=1}^M h_i(e|f) * \log \rho_i$$
 - $\log \rho_i$ son constantes (λ_i) que representan el peso de cada feature y suman 1

Log-linear phrase-based

- Permite tomar cada componente del modelo por frases y darle un peso distinto
 - Se explicitan en vez de que cada probabilidad salga de los alineamientos como en IBM
 - $\rightarrow \lambda_1 \phi(f_i | e_i) + \lambda_2 \alpha^{|\text{start}_i, \text{end}_i-1|} + \lambda_3 P(e) + \lambda_4 \omega^{|e|}$
- Se puede usar EM para estimar el valor de los $\lambda_i \rightarrow$ tuning del modelo

Ejemplo tabla de traducción

a bilateral ||| des deux cotés de ||| 0.03125
 a bilateral ||| des deux cotés ||| 0.031746
 a bilateral ||| deux cotés de la tête ||| 1
 anxious for more than six days ||| anxieux pendant plus de six jours ||| 0.5
 anxious for more than six ||| anxieux pendant plus de six ||| 0.25
 anxious for more than ten minutes ||| anxieux pendant plus de dix minutes ||| 0.5
 anxious for more than ten months ||| anxieux pendant plus de dix mois ||| 1

Modelos factorizados [Koehn 07]

- Análogo a los modelos de lenguaje factorizados
 - Una palabra w es una colección de factores, se representa como un vector
 - Ej la = ("la", artículo), gato = ("gato", sustantivo), ...
- Morfología es un buen ejemplo de la utilidad de los modelos factorizados
 - Si entrenamos el sistema solo con sustantivos en plural (ej casas, autos, perros, ...) no podremos traducir ningún sustantivo en singular
- Por otro lado, idiomas ricos morfológicamente producen muchas formas por palabra
 - Necesitaría tener cada una de esas formas en el corpus

Modelos factorizados

- Para traducir de factores a factores es necesario partir el proceso en dos
 - Mapeo de factores por separado (nivel de la frase)
 - Generación de palabra en LM a partir de factores
- Son una extensión de modelos por frases
 - Como cada paso es modelado con una feature encaja bien en modelos log-linear
 - Los pesos se obtienen con proceso de tuning

Phrase-based training

- Establish word alignment (GIZA++ and symmetrization)

	naturally	john	has	fun	with	the	game
natürlich	■						
hat		■					
john			■				
spass				■			
am					■		
spiel						■	

Slide de Koehn 2009

Phrase-based training

- Extract phrase

	naturally	john	has	fun	with	the	game
natürlich	■						
hat		■					
john			■				
spass				■			
am					■		
spiel						■	

⇒ natürlich hat john — naturally john has

Slide de Koehn 2009

Factored training

- Annotate training with factors, extract phrase

	naturally	john	has	fun	with	the	game
ADV	■						
V		■					
NNP			■				
V				■			
NNP					■		
NN						■	
P							■
NN							

⇒ ADV V NNP — ADV NNP V

Slide de Koehn 2009

El menú de hoy


- Modelos por frases
 - Sintácticos [Yamada 01]
 - Probabilidad conjunta [Marcu 02]
 - Basados en noisy-channel [Koehn 03]
 - Alignment template [Och 03]
 - Factored models [Koehn 07]
- Estimación de parámetros (MERT)
- Alineamiento de frases
- Práctico 4

MERT [Och03]

- Minimum Error-Rate Training se usa para estimar automáticamente pesos de parámetros del MT
 - También podríamos setear los λ_i a mano
- Usa el ML y alineamientos generados para entrenar MT y trata de mejorar (optimizar) los λ_i usando EM
 - La idea mejorar la calidad total del sistema (overall)
- La optimización se hace respecto a una métrica automática de la calidad de la traducción
 - Mas adelante veremos evaluación en mas detalle

MERT [Och03]

Discriminative training



Slide de Koehn 2009

MERT [Och03]

- En la practica
 - Se entrena el MT con los parámetros por default
 - Se ejecuta MERT sobre un corpus de desarrollo
 - Corpus de "dev" es una porción separada del corpus original
 - MERT genera una lista de pesos para cada feature que luego se pasa al decoder para la traducción del corpus de test
- Este proceso de tuning automático no siempre mejora la calidad de las traducciones
 - En realidad solo mejora un score automático (BLEU) que depende de los n-grams del corpus
 - → idea de proyecto: probar otras métricas en mert

El menú de hoy

- Modelos por frases
 - Sintácticos [Yamada 01]
 - Probabilidad conjunta [Marcu 02]
 - Basados en noisy-channel [Koehn 03]
 - Alignment template [Och 03]
 - Factored models [Koehn 07]
- Estimación de parámetros (MERT)
- Alineamiento de frases
- Práctico 4

Alineamiento de frases

- Es necesario aprender como se relacionan pares de frases para crear una tabla de traducción (modelo)
- Dependiendo del MT usado el alineamiento se puede hacer
 - A partir de palabras
 - Directamente del corpus
 - Por frases sintácticas ...
- Una vez alineados los pares de frases se crea una distribución de probs

Alineamiento de frases

- [Och 2003] genera alineamientos en ambas direcciones, A_e y A_f
- Para aumentar la calidad de los alineamientos se pueden combinar
 - $A = A_e \cap A_f$ contiene solo alineamientos viterbi → son muy confiables = alta precisión
 - $A = A_e \cup A_f$ contiene todos los viterbi → alto cubrimiento
 - Incremental: tomar \cap primero, agregar $(i,j) \in A_e$ ó A_f si ni f_i ni e_j tiene alguna conexión en A o si se dan estas dos condiciones
 - (i,j) tiene vecino horizontal $(i+/-1,j)$ o vertical $(i,j+/-1) \in A$
 - $AU\{(i,j)\}$ no contiene alineamientos con vecinos ver/hor


Alineamiento de frases

- La idea es extraer frases "consistentes" con los alineamientos por palabras dados por modelos IBM
 - Consistencia: palabras de un par de frases alineadas solo entre ellas (no fuera del par)
- Formalmente consistencia definida por

$$BP(f_1^j, e_1^j, A) = \{ (f_i^{j+m}, e_i^{j+n}) \};$$


$$\text{forall } (i', j') \text{ in } A : j' <= j' <= j+m <-> i <= i' <= i+n$$
- Modificaciones de este algoritmo usan un paso adicional para agregar alineamientos "no consistentes"
 - Con algun criterio para que no introduzcan ruido

Ejemplo de \cap/U



Slide de Koehn 2009

Consistent with word alignment



- Consistent with the word alignment :=

phrase alignment has to *contain all alignment points* for all covered words


$$(\bar{e}, \bar{f}) \in BP \Leftrightarrow \forall e_i \in \bar{e} : (e_i, f_j) \in A \rightarrow f_j \in \bar{f}$$

$$\text{AND } \forall f_j \in \bar{f} : (e_i, f_j) \in A \rightarrow e_i \in \bar{e}$$

Slide de Koehn 2009

Ejemplo


Word alignment induced phrases



(Maria, Mary), (no, did not), (slap, daba una bofetada), (a la, the), (bruja, witch), (verde, green)

Slide de Koehn 2009


Word alignment induced phrases



(Maria, Mary), (no, did not), (slap, daba una bofetada), (a la, the), (bruja, witch), (verde, green),
 (Maria no, Mary did not), (no daba una bofetada, did not slap), (daba una bofetada a la, slap the),
 (bruja verde, green witch)

Slide de Koehn 2009


Word alignment induced phrases



(Maria, Mary), (no, did not), (slap, daba una bofetada), (a la, the), (bruja, witch), (verde, green),
 (Maria no, Mary did not), (no daba una bofetada, did not slap), (daba una bofetada a la, slap the),
 (bruja verde, green witch), (Maria no daba una bofetada, Mary did not slap),
 (no daba una bofetada a la, did not slap the), (a la bruja verde, the green witch)
 (no daba una bofetada a la, did not slap the), (a la bruja verde, the green witch)

Slide de Koehn 2009


Word alignment induced phrases



(Maria, Mary), (no, did not), (slap, daba una bofetada), (a la, the), (bruja, witch), (verde, green),
 (Maria no, Mary did not), (no daba una bofetada, did not slap), (daba una bofetada a la, slap the),
 (bruja verde, green witch), (Maria no daba una bofetada, Mary did not slap),
 (no daba una bofetada a la, did not slap the), (a la bruja verde, the green witch),
 (Maria no daba una bofetada a la, Mary did not slap the),
 (daba una bofetada a la bruja verde, slap the green witch)

Slide de Koehn 2009

Word alignment induced phrases (5)



(Maria, Mary), (no, did not), (slap, daba una bofetada), (a la, the), (bruja, witch), (verde, green),
(Maria no, Mary did not), (no daba una bofetada, did not slap), (daba una bofetada a la, slap the)
(bruja verde, green witch), (Maria no daba una bofetada, Mary did not slap),
(no daba una bofetada a la, did not slap the), (a la bruja verde, the green witch),
(Maria no daba una bofetada a la, Mary did not slap the), (daba una bofetada a la bruja verde,
slap the green witch), (no daba una bofetada a la bruja verde, did not slap the green witch),
(Maria no daba una bofetada a la bruja verde, Mary did not slap the green witch)

Slide de Koehn 2009

Resumen

- Hoy vimos como modelar por frases en vez de palabras
 - Distintos modelos el que nos interesa es log-linear phrase-based [Koehn03]
 - Vimos como se estiman los parámetros de cada función característica (tuning)
 - MERT [Och03]
 - Vimos como se obtienen las frases alineadas para estos modelos
- estamos en condiciones de probar la traducción por frases en un nuevo práctico!

El menú de hoy

- Modelos por frases
 - Sintácticos [Yamada 01]
 - Probabilidad conjunta [Marcu 02]
 - Basados en noisy-channel [Koehn 03]
 - Alignment template [Och 03]
 - Factored models [Koehn 07]
- Estimación de parámetros (MERT)
- Alineamiento de frases
- Práctico 4

Practico 4

- Usar el mismo corpus que en el practico 3 para entrenar modelo por frases
- Traducir el mismo corpus de test del practico 3
- Comparar los resultados
- Herramientas GIZA++, Moses, SRI-LM
 - <http://www-speech.sri.com/projects/srilm/download.html>
 - <http://fjoch.com/GIZA++.html>
 - <http://www.statmt.org/moses/>

- anxious for more than ||| anxieux pendant plus de ||| (0) (1) (2) (2,3) ||| (0) (1) (2,3) (3) ||| 0.32 0.0275453 0.888889 0.0570425 2.718

- Currently, five different phrase translation scores are computed:

- * phrase translation probability $f(f|e)$
- * lexical weighting $\text{lex}(f|e)$
- * phrase translation probability $f(e|f)$
- * lexical weighting $\text{lex}(e|f)$
- * phrase penalty (always $\exp(1) = 2.718$)

Bibliografía

- A Syntax-based Statistical Translation Model <http://wing.comp.nus.edu.sg/acl/P/P01/P01-1067.pdf>
- A Phrase-Based, Joint Probability Model for Statistical Machine Translation <http://www.isi.edu/~marcu/papers/jointmt2002.pdf>
- Effective Phrase Translation Extraction from Alignment Models <http://acl.ldc.upenn.edu/acl2003/main/pdfs/Venugovu.pdf>