

# Método de Traducción Automática por Traducción Estadística

Francisco Guzmán  
CSI - ITESM

18 de abril de 2008

2° CONGRESO NACIONAL DE SISTEMAS Y COMPUTACION  
Instituto Tecnológico de Orizaba  
Orizaba, Veracruz

# Outline

- 1 Introducción
- 2 Principios de SMT
- 3 Creando un traductor estadístico
- 4 Conclusiones SMT
- 5 Paráfrasis de Traducción
- 6 Conclusiones

# Motivación...

- 4000-5000 diferentes lenguajes en el mundo



COPYRIGHT JOHN S. PRITCHETT

# Motivación...

- 4000-5000 diferentes lenguajes en el mundo
- Información en el internet en incremento exponencial




COPYRIGHT JOHN S. PRITCHETT

# Motivación...

- 4000-5000 diferentes lenguajes en el mundo
- Información en el internet en incremento exponencial
- El acceso a la información está limitado por la barrera del lenguaje.




## ...para la Traducción Automática...



- El niño juega en el parque.
- Ella comprará un libro de política internacional.
- El agua está clara pero fría.

## ...para la Traducción Automática...



- El niño juega en el parque.
- Ella comprará un libro de política internacional.
- El agua está clara pero fría.

- The boy plays in the park.
- She will buy a book on international politics.
- The water is clear but cold.

## ...para la Traducción Automática...

- Es un problema difícil.
- En sus inicios: Traducciones Basadas en Reglas
- Los 90's fueron una etapa fructífera
- Surgimiento de nuevos paradigmas, **empíricos**, con colecciones de textos (corpus) paralelos.
  - Traducciones Basadas en Ejemplos
  - Traducciones por Métodos Estadísticos

## ...para la Traducción Automática...

- Es un problema difícil.
- En sus inicios: Traducciones Basadas en Reglas
- Los 90's fueron una etapa fructífera
- Surgimiento de nuevos paradigmas, **empíricos**, con colecciones de textos (corpus) paralelos.
  - Traducciones Basadas en Ejemplos
  - Traducciones por **Métodos Estadísticos**

## ...Estadística (SMT)

- Por Brown y sus colegas en los 90's.
- Modela el proceso de traducción en terminos de probabilidades
- En su forma tradicional no hace uso de información lingüística.
- No está limitado por los pares de lenguas.

# Modelar el lenguaje

**e**: enunciado en lenguaje objetivo (ej. Inglés)

**f**: enunciado en lenguaje origen (ej. Español)

$Pr(e|f)$  = distribución de probabilidad de que **e** sea la traducción de **f**.

- Problema: no se conoce la verdadera  $Pr(e|f)$

# Modelar el lenguaje

**e**: enunciado en lenguaje objetivo (ej. Inglés)

**f**: enunciado en lenguaje origen (ej. Español)

$Pr(e|f)$  = distribución de probabilidad de que **e** sea la traducción de **f**.

- Problema: no se conoce la verdadera  $Pr(e|f)$
- Aproximación: se estima un modelo  $p(e|f)$

# Modelar el lenguaje

**e**: enunciado en lenguaje objetivo (ej. Inglés)

**f**: enunciado en lenguaje origen (ej. Español)

$Pr(e|f)$  = distribución de probabilidad de que **e** sea la traducción de **f**.

- Problema: no se conoce la verdadera  $Pr(e|f)$
- Aproximación: se estima un modelo  $p(e|f)$
- Objetivo: obtener una frase  $\hat{e}$  que maximice tal probabilidad:

# Modelar el lenguaje

**e**: enunciado en lenguaje objetivo (ej. Inglés)


**f**: enunciado en lenguaje origen (ej. Español)

$Pr(e|f)$  = distribución de probabilidad de que **e** sea la traducción de **f**.

- Problema: no se conoce la verdadera  $Pr(e|f)$
- Aproximación: se estima un modelo  $p(e|f)$
- Objetivo: obtener una frase  $\hat{e}$  que maximice tal probabilidad:

$$\hat{e}(f) = \arg \max_e Pr(e|f)$$

# ¿Canal ruidoso?



- Tenemos que suponer “la historia a la inversa”
- Pensamos que el texto se originó en Inglés
- Algún proceso “ruidoso” lo transformó en español
- E intentaremos “reconstruirlo” al inglés con la evidencia que tenemos.

## ¿Canal ruidoso?

$$\begin{aligned}\hat{e}(f) &= \arg \max_e Pr(e|f) \\ &= \arg \max_e \frac{Pr(f|e)Pr(e)}{Pr(f)} \\ &= \arg \max_e Pr(f|e)Pr(e) \\ &\approx \arg \max_e p(f|e)p(e)\end{aligned}$$

- Tenemos que suponer “la historia a la inversa”
- Pensamos que el texto se originó en Inglés
- Algún proceso “ruidoso” lo transformó en español
- E intentaremos “reconstruirlo” al inglés con la evidencia que tenemos.

# Modelos

$$\hat{e} = \mathit{arg} \max_e p(f|e)p(e)$$

## modelo de lenguaje $p(e)$

- Nos da una probabilidad de qué tan “común” es cierta construcción en el lenguaje objetivo.
- Esto nos asegura cierta validez gramatical.
- $p(\text{Voy Orizaba conferencia a unas mañana}) \Rightarrow$  muy poco probable
- $p(\text{Mañana voy a Orizaba a una conferencia}) \Rightarrow$  mucho mejor

# Modelos

$$\hat{e} = \arg \max_e p(f|e)p(e)$$

## modelo de traducción $p(f|e)$

- Es la probabilidad de que una frase se traduzca en otra
- Es tan complejo como estimar  $p(e|f)$
- Se basa en alineaciones
- $p(\text{ la casa es azul } | \text{ the martians are going to attack!!}) \Rightarrow$   
poco probable
- $p(\text{ la casa es azul } | \text{ the house is blue}) \Rightarrow$  mejor

# Modelos

$$\hat{e} = \arg \max_e p(f|e)p(e)$$

## modelo de traducción $p(f|e)$

- Es la probabilidad de que una frase se traduzca en otra
- Es tan complejo como estimar  $p(e|f)$
- Se basa en **alineaciones**
- $p(\text{ la casa es azul } | \text{ the martians are going to attack!!}) \Rightarrow$   
poco probable
- $p(\text{ la casa es azul } | \text{ the house is blue}) \Rightarrow$  mejor

# Alineaciones

- Primeros modelos basados en palabras


# Alineaciones

- Primeros modelos basados en palabras
- Modelos más recientes basados en “frases”

# Alineaciones


- Primeros modelos basados en palabras
- Modelos más recientes basados en “frases”
- Phrase-Based Statistical Machine Translation

# Modelos de alineación palabra-palabra



El proceso de traducción se descompone en varios pasos  
Modelos originales de Brown (1993) (IBM-1, IBM-2 ... IBM-5)


## Un paso adelante... frases



from Koehn et al.


- La entrada a traducir se segmenta en secuencias de palabras que se conocen como “frases”.
- Esta denominación no tiene una motivación lingüística.
- Las frases se reordenan.
- Se usan heurísticas para determinar las alineaciones, basadas en las alineaciones palabra-palabra.
- Las probabilidades obtenidas se guardan en “tablas de frases”

## Ejemplo




from Koehn et al.

## Ejemplo




from Koehn et al.

# Ejemplo



from Koehn et al.

# Proceso de Traducción



# Decodificación

- Existen muchas posibles formas de segmentar la frase de entrada.
- Existen muchas posibles traducciones.
- Se van creando “hipótesis” de traducción
- Se trata de un problema de búsqueda entre la “hipótesis” que maximice el resultado.
- Explosión exponencial del espacio de búsqueda.
- Se ha comprobado que es NP-Difícil.
- Se han creado diferentes heurísticas para atacar este problema

# ¿Cómo crear un traductor?

## Obtención de datos

- Se necesitan GRANDES cantidades de texto para entrenar...

# ¿Cómo crear un traductor?

Obtención de datos

Preprocesamiento

- Se limpian los corpus para eliminar datos “no deseados”.

# ¿Cómo crear un traductor?

Obtención de datos

Preprocesamiento

Entrenamiento

- Se entrena el modelo de lenguaje usando SRILM.
- Se entrena el modelo de traducción usando GIZA++.
- Se obtienen tablas de frases.

# ¿Cómo crear un traductor?

Obtención de datos

Preprocesamiento

Entrenamiento

Decodificación

- Se hace entrenamiento de parámetros (MERT) del decodificador.
- Se usan las tablas de frases para decodificar.

# ¿Cómo crear un traductor?

Obtención de datos

Preprocesamiento

Entrenamiento

Decodificación

Evaluación

- Se utilizan métricas automáticas (BLEU)

# Disponibilidad

## Textos Paralelos:

- Europarl: 30 millones de palabras en 11 lenguajes  
<http://www.statmt.org/europarl/>
- Acquis Communautaire: 8-50 millones de palabras en 20 lenguajes de la UE.
- Muchos más...

## Textos Monolingües (para modelado de lenguaje)

- 2800 millones de palabras en Inglés del LDC
- Cientos de millones en la web

# Ejemplos:

## Europarl

1 adoption of the minutes of the previous sitting

2 the minutes of yesterday's sitting have been distributed .

3 are there any comments ?

aprobación del acta de la sesión anterior

el acta de la sesión anterior ha sido distribuida .

¿ hay alguna objeción ?

# Evaluación

- ¿Por qué se hace una evaluación automática?
- Evaluación manual es muy lenta (y costosa)
- Evaluación automática por excelencia: BLEU
- Se trata de comparar una traducción hecha por un sistema, contra una traducción de referencia...
- Se ha comprobado que BLEU tiene alta correlación con las evaluaciones de los jueces humanos.

# La batalla no está ganada

- La SMT ha probado ser MUY efectiva
- Permite traducir de  $A \rightarrow B$  indiscriminadamente

# La batalla no está ganada

- La SMT ha probado ser MUY efectiva
- Permite traducir de  $A \rightarrow B$  indiscriminadamente

**pero...**

# La batalla no está ganada

- La SMT ha probado ser MUY efectiva
- Permite traducir de  $A \rightarrow B$  indiscriminadamente

## pero...

- Está limitada por el **entrenamiento** y la disponibilidad de recursos
- Esto es un problema cuando tratamos de traducir entre lenguajes “poco densos”



Aprender de otros

# ¿Qué tal si...

# ¿Qué tal si...

**Pudiéramos aprender de un lenguaje, mirando a otros lenguajes?**

# ¿Qué tal si...

## Pudiéramos aprender de un lenguaje, mirando a otros lenguajes?

- Se extraen paráfrasis mediante la traducción de  $A \rightarrow B$
- Se usan esas paráfrasis para PB-SMT (Callison-Burch) como una variable más

# ¿Qué tal si...

## Pudiéramos aprender de un lenguaje, mirando a otros lenguajes?

- Se extraen paráfrasis mediante la traducción de  $A \rightarrow B$
- Se usan esas paráfrasis para PB-SMT (Callison-Burch) como una variable más

## Pudiéramos aprender cómo traducir de A a B, mirando a C

# ¿Qué tal si...

## Pudiéramos aprender de un lenguaje, mirando a otros lenguajes?

- Se extraen paráfrasis mediante la traducción de  $A \rightarrow B$
- Se usan esas paráfrasis para PB-SMT (Callison-Burch) como una variable más

## Pudiéramos aprender cómo traducir de **A** a **B**, mirando a **C**

- Traducciones indirectas ( $\text{Eng} \rightarrow \text{Esp} \rightarrow \text{Cat}$ ) (Gispert)
- Traducción de una parte del corpus.

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)

The child wants a candy

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)

The child wants a candy  
⇕  
The infant desires a sweet

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)

The child wants a candy



The infant desires a sweet



*El niño quiere un dulce*

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)
- **Paráfrasis de Traducción** diferentes pares de frases con la misma carga semántica

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)
- **Paráfrasis de Traducción** diferentes pares de frases con la misma carga semántica

el niño quiere un dulce ↔ *the child wants a candy*

# Paráfrasis de traducción

- **Paráfrasis** son diferentes frases con la misma carga semántica. (mismo significado)
- **Paráfrasis de Traducción** diferentes pares de frases con la misma carga semántica

el niño quiere un dulce ↔ *the child wants a candy*



l'enfant veut un bonbon ↔ *the child desires a sweet*

## ... en acción ...

spanish- french

El niño quiere un dulce  
L'enfant veut un bonbon

+

french-english

L'enfant veut un bonbon  
The child wants a candy

↓

spanish-english

El niño quiere un dulce  
The child wants a candy

- Se usa un lenguaje intermediario para obtener las PTs.
- Se combinan dos pares de traducción para obtener uno nuevo.
- Las probabilidades se calculan de la siguiente manera:

$$p(es|en) = \sum_{fr} p(es|fr)p(fr|en)$$

## ... en acción ...




- Se usa un lenguaje intermediario para obtener las PTs.
- Se combinan dos pares de traducción para obtener uno nuevo.
- Las probabilidades se calculan de la siguiente manera:

$$p(es|en) = \sum_{fr} p(es|fr)p(fr|en)$$



## ... para enriquecer las tablas de frases

- Se obtienen por medio de un lenguaje intermediario
- Nos ayudan a obtener interpretaciones más flexibles






# Question

¿Qué tanto se puede mejorar la traducción usando las PTs?



# Resultados de Comparaciones



# Conclusiones

- Mientras se incrementa el tamaño de los corpus de entrenamiento, las TPs tienen menor impacto
- En casos donde hay poco entrenamiento, la mejora de la calidad es SIGNIFICATIVA
- Las TPs por sí solas, no dan buenos resultados.

# ¿Preguntas?

# Centro de Sistemas Inteligentes

Si están interesados en la Traducción Automática o la Inteligencia Artificial en general:

- Maestrías y Doctorados en ITESM Campus Monterrey:
- <http://sistemas-inteligentes.mty.itesm.mx>