

# Grados de similitud de relaciones

Alisa Zhila (Instituto Politécnico Nacional)

Scott Yih (MSR)

Chris Meek (MSR)

Puebla, 19 de octubre 2012



# Introducción: relaciones en pares de palabras

- rueda : coche Parte-de
- carro : coche Sinónimos
- perro : animal Es-un
- broma : risa Causa-efecto

# Grados de similitud de relaciones

Relación Es-un

mamífero: primate

mamífero : ballena

mamífero : masopa

ENTIDAD:SONIDO

perro : ladrido ✓

coche : vroom

gato : maullido ✓



$Prob[(ballena, mamífero) \in Es-un]$

Clasificación de relaciones discreta pierde esos detalles

# Aplicaciones

- **Búsqueda**
    - Búsqueda relacional: resultados clasificados por el grado de relación
      - Partes de coche: rueda, defensa, ..., limpiaparabrisas
    - Búsqueda por analogía
      - perro : ladrar = vaca : ?
  - **Educación**
    - Pruebas GRE, SAT
      - lull : trust*
        - balk : fortitude
        - betray : loyalty
        - cajole : compliance
        - hinder : destination
        - soothe : passion

¿Qué tan difícil es determinar que dos pares de palabras expresan la misma relación?
- **Análisis/Parsing semántico**

# Tarea & Resultados

- SemEval-2012 Task 2: Measuring Degrees of Relational Similarity
  - Pares de palabras en 79 categorías de relaciones
  - Ordenar los pares de palabras en cada categoría por la correlación a un estándar de oro existente
- Nuestros resultados
  - Precisión 39.4 -> **43.0** (más 9%)
  - Coeficiente de Spearman 0.229 -> **0.305** (más 33%)



# Agenda

- **Introducción**
- **Tarea**
- **Metodología**
  - **Características**
  - **Clasificador**
- **Resultados**
- **Conclusiones y trabajo futuro**



# Agenda

- **Introducción**
- **Tarea**
- **Metodología**
  - **Características**
  - **Clasificador**
- **Resultados**
- **Conclusiones y trabajo futuro**



# Pares de Palabras y Relaciones

- 10 categorías mayores:
  - Inclusión de una clase (Es-un)
  - Parte-Entero
  - Similitud
  - Contraste
  - Atributo
  - No-Atributo
  - Causa-Efecto
  - Espacio -Tiempo
  - Referencia
  - Casos de Relaciones Especiales
- 5-9 grupos de relaciones más finas en cada categoría
- 79 grupos × 40 pares de palabras

# Tarea: Escoger Mejores/Peores Pares

- 4 pares seleccionados al azar de un grupo de 40 pares
- Presentarlos a un anotador humano para escoger el mejor y el peor par

Taxonomía: Y es un tipo de X

“roble:árbol” “verdura:perejil” “árbol:roble” “moneda:dolar”

~100 veces en cada categoría incluyendo todos los pares

- Formar un *Gold Standard*



# Métricas de evaluación

- Precisión de selección
  - Si las selecciones del mejor/peor coinciden con los de anotadores humanos
- Coeficiente de Spearman para el orden de toda la lista
  - Qué tan bueno es el orden de la lista producido por el sistema con respecto al Gold Standard



# Agenda

- Introducción
- Tarea
- **Metodología**
  - **Características**
  - **Clasificador**
- Resultados
- Conclusiones y trabajo futuro

# Metodología: Modelo de aprendizaje

Q: (oak, tree), (vegetable, carrot), (tree, oak), (currency, dollar)

- Aprender un clasificador probabilístico:  
 $Prob[(w_1, w_2) \in Rel]$
- Escoger el mejor y el peor par según los coeficientes

## Entrenamiento

36 ejemplos positivos

3000 negativos

## Prueba

4 pares de palabras de cada pregunta

- Asignar coeficientes a los pares usando el clasificador
- Aprender un modelo independiente para cada 4 pares en preguntas (8000 modelos en total)
- Para cada 4 pares de prueba determinar el mejor y el peor par

# Metodología

## Características:

- Valores de funciones existentes para cada par de palabras
  - Bases del conocimiento: Probase IsA y Attribute (Wang *et al.*, MSR)
  - Sinónimo/Antónimo: PILSA (Yih *et al.*, MSR)
  - Similitud en el espacio vectorial: modelo de lenguaje sobre la red neuronal recurrente (RNN) (Zweig and Mikolov, MSR)
- Patrones textuales extraídos de corpus
  - X:Y -> 'X of the Y'

## Classificador:

TLC FastRank




# Agenda

- Introducción
- Tarea
- Metodología
  - Características
  - Clasificador
- **Resultados**
- Conclusiones y trabajo futuro

# Resultados


## Precisión



mejora de 9 %

# Resultados

## Spearman



mejora de 33 %

# Resultados

Categorías de relaciones	UTD-NB	MSR
1 INCLUSIÓN DE UNA CLASE		✓
2 PARTE-ENTERO		✓
3 SIMILITUD	✗	
4 CONTRASTE		✓
5 ATRIBUTO		✓
6 NO-ATRIBUTO		✓
7 RELACIONES ESPECIALES		✓
8 CAUSA-EFECTO		✓
9 ESPACIO-TIEMPO	✗	
10 REFERENCIA	✗	

7 categorías ganadoras entre 10

# Análisis

- Inclusión de una clase -Taxonómico

"art:abstract", "bread:wheat", "pet:dog" (0.360), "dog:pet" (0.002)

- Probase IS-A
- 'such as'

- Parte-Entero -Colección:Miembro

"herd:elephant", "flock:bird", "soldiers:army" (0.049), "library:book" (0.991)

- 'consisting of'
- 'of'

# Análisis – Espacio para mejora

- ESPACIO-TIEMPO – Tiempo: Artículo Asociado

Ejemplo: *‘jubilación:pensión’*

- ‘education and’
- ‘and a big’
- No hay patrones textuales específicos
- Ninguna característica es principal



# Conclusiones y trabajo futuro

## Resultados del estado-del-arte

- Introdujimos características basadas en otros sistemas
- Distintas configuraciones de aprendizaje automático

## Trabajo futuro:

- Direcciones para mejora:
  - Mejorar las características
  - Análisis de errores más profundo
- Eficacia del modelo actual y sus aplicaciones



**Additional slides**

# RNN Language Model

- Word vector embeddings  $\vec{w}_1, \vec{w}_2$
- Word pair vectors:  $\vec{w_1:w_2} = \vec{w}_1 - \vec{w}_2$
- Each group has 3 “gold standard” example pairs out of the list :  $\vec{g_1:g_2}$
- Word pair vector similarity:  
$$\cos(\vec{w_1:w_2}, \vec{g_1:g_2})$$