

# Extracción de Información

- Extracción de entidades con nombre
- Instanciación de Entidades con Nombre
- Extracción de relaciones

# Instanciación de entidades con nombre

- Uruguay
  - País
  - Río
  - Calle
  - Nombre de persona
- Los nombres propios no son identificadores unívocos de entidades del mundo.

# Instanciación de entidades con nombre

- Una vez que hemos reconocido un nombre de entidad, debemos **desambiguarlo**.
- La **clasificación** (Persona, Lugar Geográfico, Organización, etc.) es un 1er paso en la desambiguación, pero no basta.
- Para desambiguar, necesitamos un **repertorio de valores posibles**. En el caso de palabras comunes, estos repertorios son los **diccionarios**.
- Se ha usado la wikipedia como fuente de conocimiento para la desambiguación : **wikification**

# *Wikification*

- Vincular entidades con nombre en textos con referentes en la wikipedia.
- No todas los referentes van a estar descriptos en la wikipedia, pero si los que involucren conocimiento “enciclopédico”.
- Otras desambiguaciones se harán en un contexto local

# Wikificación

- Wikipedia, “Montevideo desambiguación”

Por **Montevideo** pueden entenderse los siguientes conceptos:

## Geográficos [\[ editar \]](#)

---

- **Montevideo**, ciudad capital del Uruguay.
- **Departamento de Montevideo**, departamento que incluye a la ciudad anterior.
- **Área Metropolitana de Montevideo**, conglomerado urbano que incluye localidades cercanas.
- **Cerro de Montevideo**, cerro de la ciudad homónima.
- **Cerro Montevideo**, cerro de las Islas Malvinas.
- **Bahía de Montevideo**.
- **Montevideo (Estados Unidos)**, localidad de Minnesota en Estados Unidos.
- **Distrito de Montevideo**, en la provincia de Chachapoyas, Departamento de Amazonas, Perú.
- **Montevideo Chico**, localidad uruguaya del departamento de Tacuarembó.

# Extracción de relaciones

- Identificadas las entidades se busca extraer relaciones entre estas.
- La mayor parte de los trabajos:
  - relaciones entre entidades mencionadas en la misma oración
  - relaciones predeterminadas (dirección de una empresa, empresa donde trabaja una persona, etc.)
  - relaciones binarias; se habla de extracción de eventos cuando hay más de 2 argumentos

# Extracción de relaciones

El **presidente Tabaré Vázquez** se **reunirá** hoy con su par **brasileño Michel Temer** en **Nueva York**, a donde **viajó** para participar de la **Asamblea de Naciones Unidas**. También se reunirá con la **directora general** de la **OMS**, **Margaret Chan**.

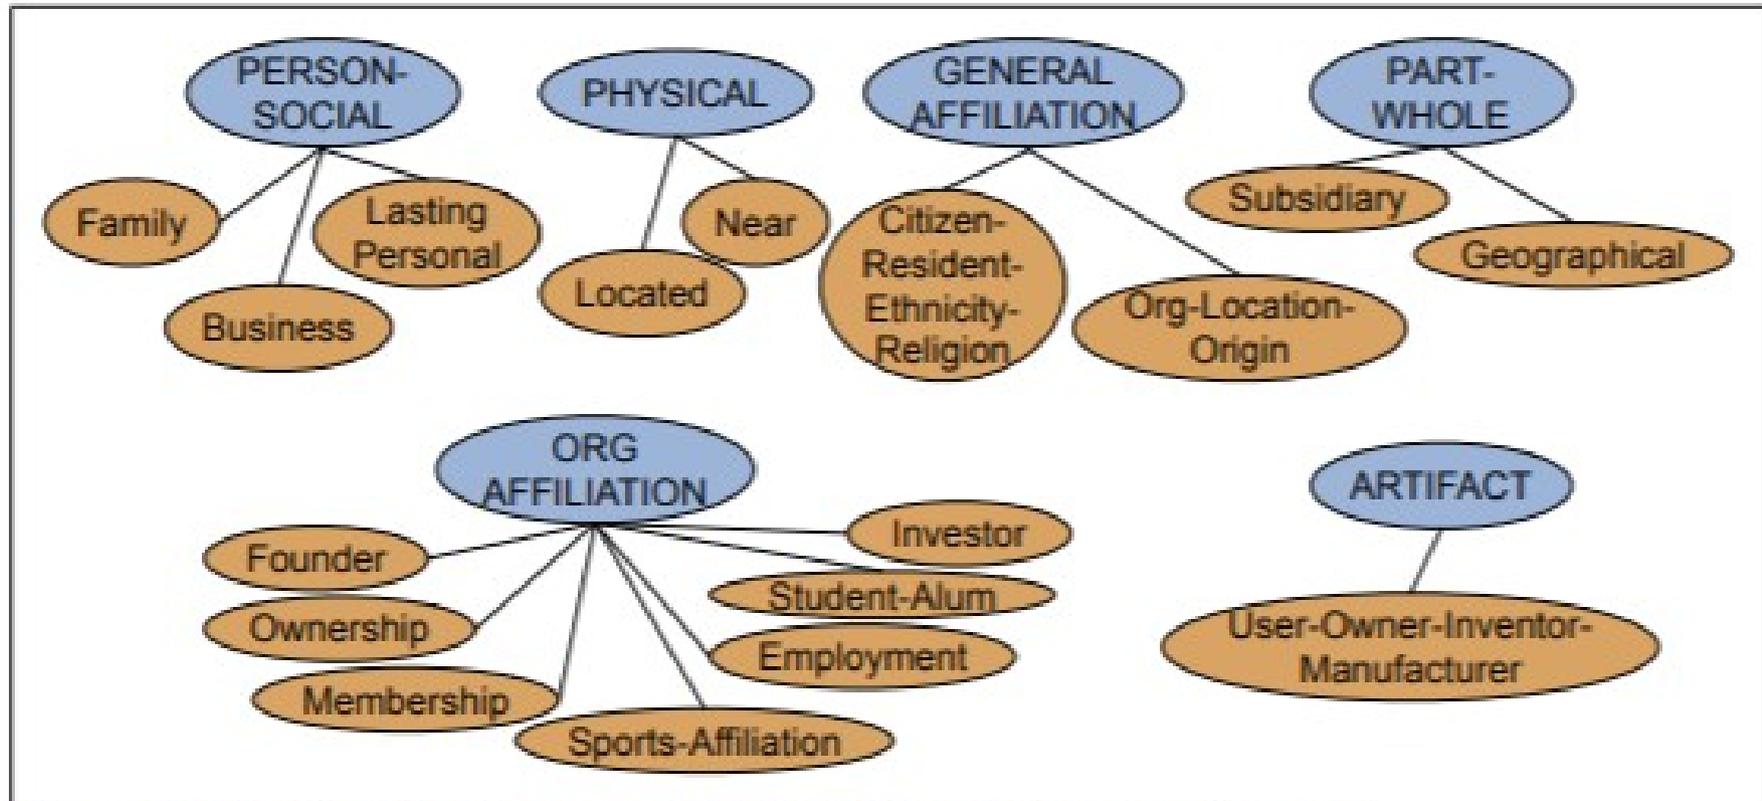
- 1) Relación : reuniones de mandatarios o personalidades
- 2) 2 argumentos: A se reúne con B
- 3) En la última oración no funcionaría a no ser que se recupere el sujeto omitido.
- 4) Podríamos agregar DONDE y CUANDO es la reunión. Ya no sería extracción de relaciones sino de **eventos**

# Extracción de relaciones

El presidente **Tabaré Vázquez** se reunirá hoy con su par **brasileño Michel Temer** en **Nueva York**, a donde viajó para participar de la **Asamblea de Naciones Unidas**. También se reunirá con la **directora general de la OMS, Margaret Chan**.

- Otras relaciones que se informan:
  - presidente de
  - director general de
  - viaje a

# Conferencia ACE 2008



**Figure 18.9** The 17 relations used in the ACE relation extraction task.

Relaciones agrupadas en clases : p.ej., hay 7 relaciones en la clase afiliación a una organización.

# Conferencia ACE 2008

Relations	Types	Examples
Physical-Located	PER-GPE	He was in Tennessee
Part-Whole-Subsidiary	ORG-ORG	XYZ, the parent company of ABC
Person-Social-Family	PER-PER	Yoko's husband John
Org-AFF-Founder	PER-ORG	Steve Jobs, co-founder of Apple...

**Figure 18.10** Semantic relations with examples and the named entity types they involve.

Notar que las relaciones que se extraen son proposiciones contingentes, o sea, predicados aplicados a argumentos que se hacen verdaderos o falsos al instanciarse en una situación y entidades específicas.

En extracción de relaciones no se trata el tema de los intervalos temporales de validez de una relación, pero si cuando se trata de extraer eventos o estados.

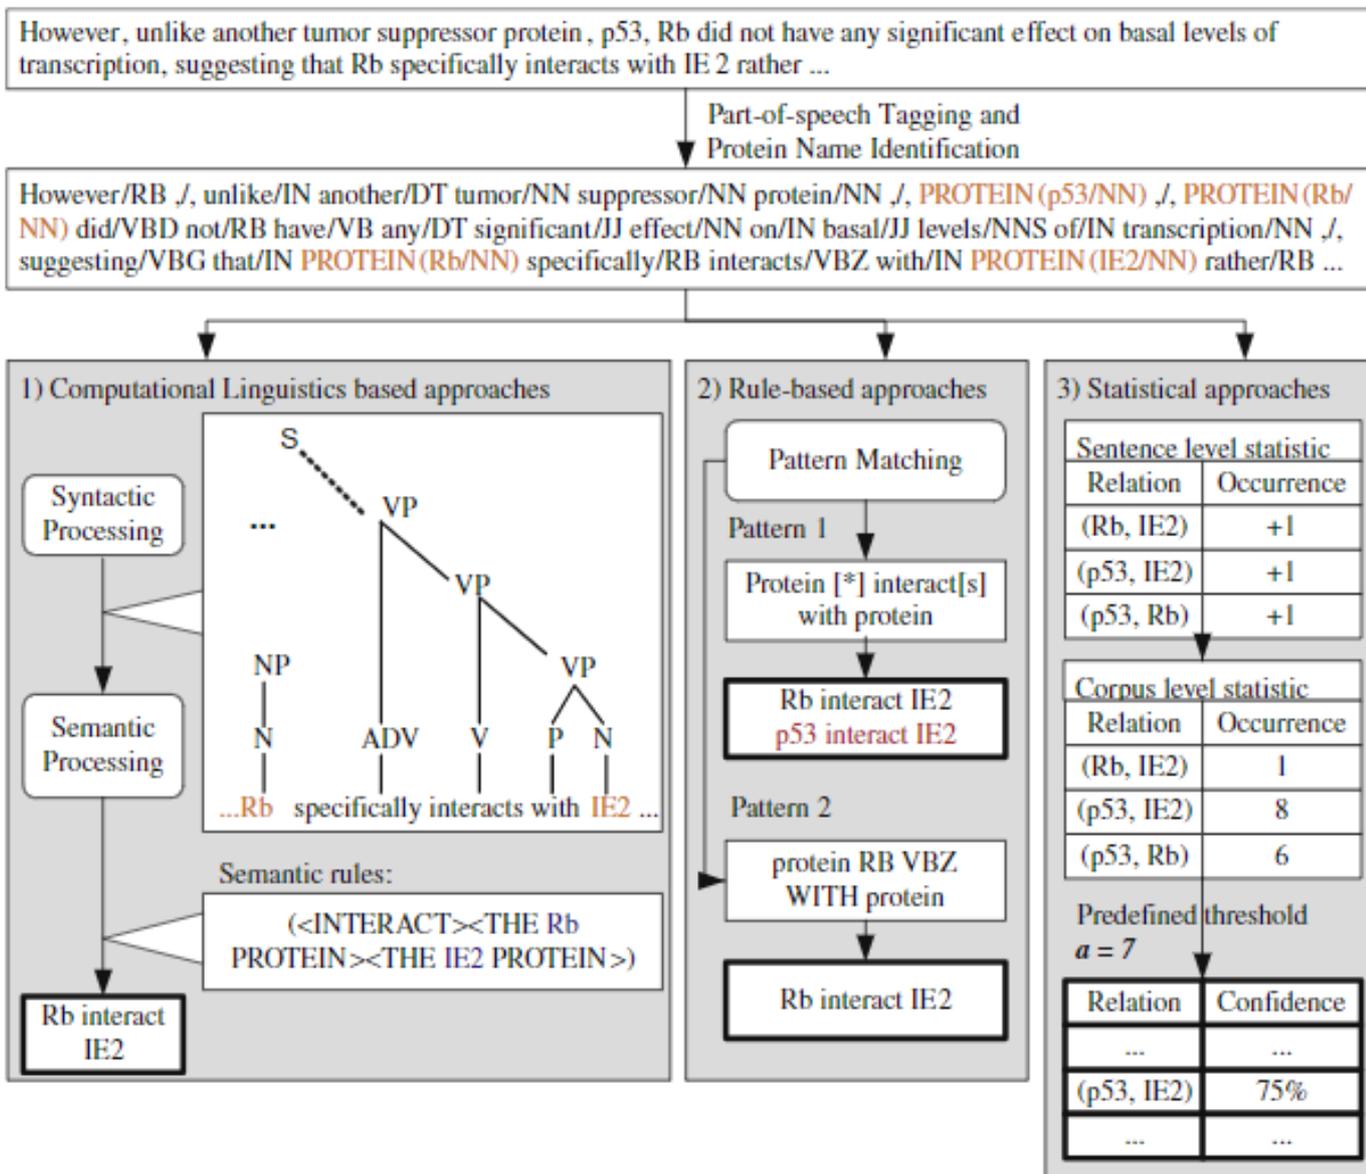


Fig. 3. General dataflow of information extraction system employing different methodologies.

# WordNet, acepciones

## WordNet Search - 3.1

- [WordNet home page](#) - [Glossary](#) - [Help](#)

Word to search for:

Display Options:

Key: "S:" = Show Synset (semantic) relations, "W:" = Show Word (lexical) relations

Display options for sense: (gloss) "an example sentence"

### Noun

- **S: (n) plant**, [works](#), [industrial plant](#) (buildings for carrying on industrial labor) *"they built a large plant to manufacture automobiles"*
- **S: (n) plant**, [flora](#), [plant life](#) ((botany) a living organism lacking the power of locomotion)
- **S: (n) plant** (an actor situated in the audience whose acting is rehearsed but seems spontaneous to the audience)
- **S: (n) plant** (something planted secretly for discovery by another) *"the police used a plant to trick the thieves"; "he claimed that the evidence against him was a plant"*

# WordNet, hipérnimos

## WordNet Search - 3.1

- [WordNet home page](#) - [Glossary](#) - [Help](#)

Word to search for:

Display Options:

Key: "S:" = Show Synset (semantic) relations, "W:" = Show Word (lexical) relations

Display options for sense: (gloss) "an example sentence"

### Noun

- [S: \(n\) dog](#), [domestic dog](#), [Canis familiaris](#) (a member of the genus *Canis* (probably descended from the common wolf) that has been domesticated by man since prehistoric times; occurs in many breeds) "*the dog barked all night*"
  - [direct hyponym / full hyponym](#)
  - [part meronym](#)
  - [member holonym](#)
  - [direct hypernym](#) / [inherited hypernym](#) / [sister term](#)
    - [S: \(n\) canine](#), [canid](#) (any of various fissioned mammals with nonretractile claws and typically long muzzles)
    - [S: \(n\) domestic animal](#), [domesticated animal](#) (any of various animals that have been tamed and made fit for a human environment)

# Relaciones en Wordnet

- Hipéónimo / hipónimo (animal, perro)
- Holónimo / merónimo (auto, motor)
- Clase / instancia (Cantante de Rock, Elvis)

# WordNet, instancia

## WordNet Search - 3.1

- [WordNet home page](#) - [Glossary](#) - [Help](#)

Word to search for:

Display Options:

Key: "S:" = Show Synset (semantic) relations, "W:" = Show Word (lexical) relations

Display options for sense: (gloss) "an example sentence"

### Noun

- [S: \(n\) Presley](#), **Elvis Presley**, [Elvis Aron Presley](#) (United States rock singer whose many hit records and flamboyant style greatly influenced American popular music (1935-1977))
  - [instance](#)
    - [S: \(n\) rock star](#) (a famous singer of rock music)

# Extracción de relaciones: métodos

1) Reglas manuales, patrones

2) Aprendizaje supervisado

3) Semi-supervisado, conjunto semilla

4) Semi-supervisado, supervisión distante

5) Completamente no supervisado, extracción abierta.

# Patrones para extracción de relaciones

Método más antiguo (Marti Hearst, 1992)

NP {, NP}* {,} (and or) other NP <sub>H</sub>	temples, treasuries, and other important <b>civic buildings</b>
NP <sub>H</sub> such as {NP,}* {(or and)} NP	<b>red algae</b> such as Gelidium
such NP <sub>H</sub> as {NP,}* {(or and)} NP	such <b>authors</b> as Herrick, Goldsmith, and Shakespeare
NP <sub>H</sub> {,} including {NP,}* {(or and)} NP	<b>common-law countries</b> , including Canada and England
NP <sub>H</sub> {,} especially {NP,}* {(or and)} NP	<b>European countries</b> , especially France, England, and Spain

**Figure 18.12** Hand-built lexico-syntactic patterns for finding hypernyms, using {} to mark optionality (Hearst 1992a, Hearst 1998).

La relación es la hipernimia, el hipónimo está escrito en azul.

# Patrones para extracción de relaciones

- Los patrones manuales suelen tener alta precisión pero bajo recall.
- Las distintas reglas pueden interactuar de modo no previsto.
- El agregado de una regla puede interferir con las anteriores.
- Se suelen usar en una 1era etapa, p.ej. para generar un conjunto de ejemplos para supervisión.

# Métodos supervisados

En general se procede por etapas, primero las entidades y luego las relaciones.

Tipos de métodos:

## **Aprendizaje supervisado**

La idea es entrenar un clasificador por cada relación, que para cada par de entidades en una oración nos diga si están o no en esa relación (la relación del clasificador, otra opción en un clasificador multiclase)

Atributos:

- Núcleo y tipo de las entidades
- Distancia entre las entidades
- Secuencia de palabras entre las entidades
- **Camino de dependencias entre las entidades**
- Otros

# Métodos semi-supervisados

## Bootstrapping

Se empieza por un conjunto semilla para una relación  $R$  de pares de entidades (o sea, un conjunto de pares)

1. Se encuentran oraciones (web u otro corpus) donde están ambas entidades.
2. Se extrae y generaliza el contexto alrededor de las entidades para extraer nuevos patrones

# Métodos semi-supervisados

## Bootstrapping

```
function BOOTSTRAP(Relation R) returns new relation tuples  
  
  tuples ← Gather a set of seed tuples that have relation R  
  iterate  
    sentences ← find sentences that contain entities in tuples  
    patterns ← generalize the context between and around entities in sentences  
    newpairs ← use patterns to grep for more tuples  
    newpairs ← newpairs with high confidence  
    tuples ← tuples + newpairs  
  return tuples
```

**Figure 18.15** Bootstrapping from seed entity pairs to learn relations.

# Bootstrapping

(AUTOR,LIBRO) — (CORTÁZAR, RAYUELA)

- Hoy os traemos un artículo dedicado a la obra fundamental de Julio Cortázar, "Rayuela".
- En la novela Rayuela (1963), **Julio Cortázar** rompe con la concepción tradicional de la narrativa ...
- Una de las obras más destacadas de Cortázar es Rayuela, un clásico de la literatura universal.
- En estos momentos, el juego formal que proponía Cortázar en Rayuela puede parecer pretencioso y un tanto innecesario.
- **Rayuela es una novela del** escritor argentino **Julio Cortázar**.

# Bootstrapping

(AUTOR,LIBRO) — (CORTÁZAR, RAYUELA)

- Hoy os traemos un artículo dedicado a la obra fundamental de Julio Cortázar, "Rayuela". / obra ? de [autor], [obra] /
- En la novela Rayuela (1963), Julio Cortázar rompe con la concepción tradicional de la narrativa ... /en ?? [obra] ?, [autor] /
- Una de las obras más destacadas de Cortázar es Rayuela, un clásico de la literatura universal. /obra ??? de [autor] es [obra] /
- En estos momentos, el juego formal que proponía Cortázar en Rayuela puede parecer pretencioso y un tanto innecesario.
- Rayuela es una novela del escritor argentino **Julio Cortázar**.

# Bootstrapping

## Evaluación de un pattern generado

Dado un pattern  $p$ , un conjunto actual de pares  $T_1$  y de patterns  $P_1$  y un conjunto  $T_n$  de pares nuevos que satisfacen el pattern

- Productividad ( $pr$ ), cuántos pares nuevos correctos generó
- Error ( $er$ ), cuántos pares nuevos incorrectos generó
- Novedad, cuántos de los pares de  $T_n$  no se generan por  $P_1$  ( $nov$ )
- $valor(p) \approx f(nov \uparrow, er \downarrow)$

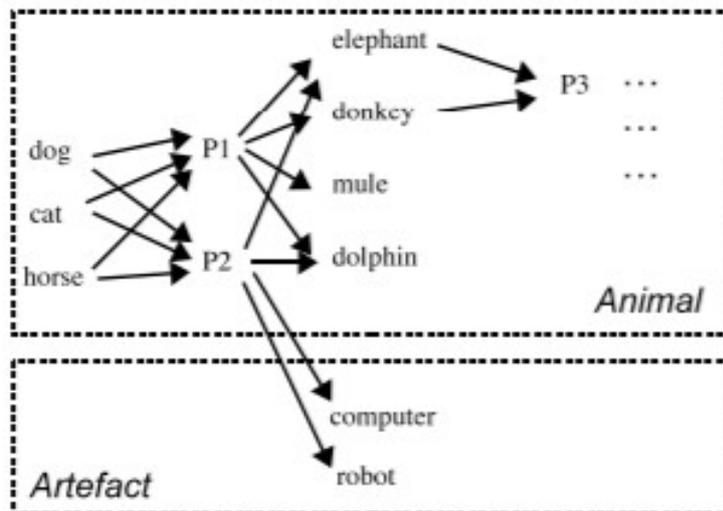
# Bootstrapping

Las reglas generadas por el contexto de un par en la relación pueden ocasionar una “mutación” de significado.

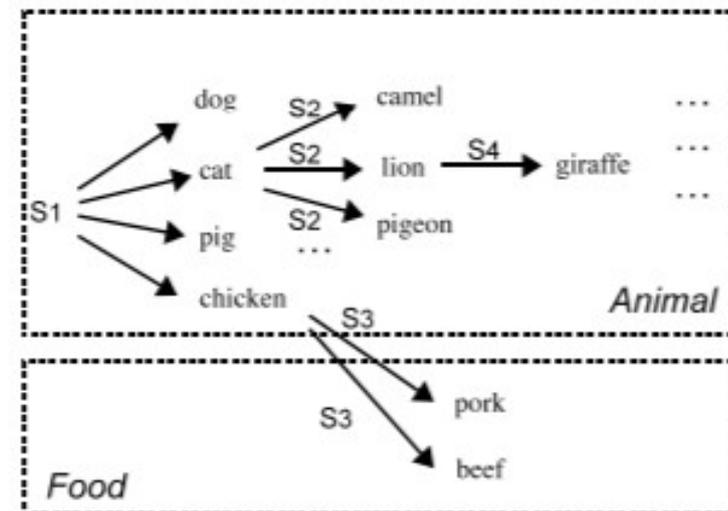
Se produce lo que se llama *semantic drift* (alteración del significado).

Vemos un ejemplo con 2 tipos de inducción de patterns

# Semantic drift - IE



(a) "syntax-based" bootstrapping mechanism



(b) "semantic-based" bootstrapping mechanism

Figure 1: Snapshots of Iterative Extraction for "Animal" with Two Different Bootstrapping Mechanisms

Overcoming Semantic Drift in Information Extraction  
 Zhixu Li , Hongsong Li, Haixun Wang, Yi Yang, Xiangliang  
 Zhang, Xiaofang Zhou b #6

# *Semantic drift – “deriva semántica”*

- En el caso de pattern sintáctico, se puede adoptar erróneamente el pattern “ as clever as human being”, que introdujo exitosamente a los delfines pero puede introducir a los robots y a las computadoras y a patterns derivados de ellos.
- El ejemplo con patterns semánticos es similar, por aplicación errónea del pattern se empieza a considerar que *beef* y *pork* son animales

Overcoming Semantic Drift in Information Extraction  
Zhixu Li , Hongsong Li, Haixun Wang, Yi Yang, Xiangliang  
Zhang, Xiaofang Zhou †6

# Supervisión distante

- Es también un método semi-supervisado de extracción de relaciones.
- A diferencia de bootstrapping, se supone que se dispone de un conjunto grande de pares en la relación. (Por ej., pares en DBPedia)
- Se buscan instancias de esos pares en la web y se obtiene un conjunto de oraciones que se pueden usar como ejemplos anotados.
- Con un conjunto grande de ejemplos se puede optar por proponer atributos y hacer aprendizaje supervisado, o directamente plantear una red neuronal

# Supervisión distante

```
function DISTANT SUPERVISION(Database D, Text T) returns relation classifier C  
  
  foreach relation R  
    foreach tuple (e1, e2) of entities with relation R in D  
      sentences  $\leftarrow$  Sentences in T that contain e1 and e2  
      f  $\leftarrow$  Frequent features in sentences  
      observations  $\leftarrow$  observations + new training tuple (e1, e2, f, R)  
  C  $\leftarrow$  Train supervised classifier on observations  
  return C
```

**Figure 18.16** The distant supervision algorithm for relation extraction. A neural classifier might not need to use the feature set  $f$ .

# Supervisión distante

## Ejemplo

Snow et al, 2005, usaron WordNet para extraer hipérmimos

Indujeron los 4 patrones originales de Hearst(1992), además de otros 70.000 :

NPH like NP — Many hormones like leptin...

NPH called NP — using a markup language called XHTML

NP is a NPH — Ruby is a programming language...

NP, a NPH — IBM, a company with a long...

Inconveniente : Se precisa un conjunto grande de pares

# Extracción abierta (*OPEN IE*)

No hay datos de entrenamiento.

No hay patrones iniciales.

Solo hay TEXTO !!! Mucho texto

Queremos extraer relaciones, tuplas de relaciones.

# Reverb

Usa herramientas de pipeline PLN y heurísticas varias para “adivinar” la expresión de una relación y de sus argumentos.

La intuición para una relación es que está expresada por un verbo (predicado). En realidad, es una unidad verbal multiplabra

*El caballo **trató de pasar** a su contricante.*

*El gobierno **está promoviendo** la exportación en el agro.*

# Reverb

Se extraen relaciones.

Se filtran las que no ocurren con al menos 20 argumentos diferentes

Se puntúan con un factor de confianza

Ejemplo:

United **has a hub** in Chicago, which **is the headquarters** of United Continental Holdings.

# Reverb

- Ejemplo:  
United **has a hub** in Chicago, which **is the headquarters** of United Continental Holdings.
- r1: <United, has a hub in, Chicago>
- r2: <Chicago, is the headquarters of, United Continental Holdings>