

OpenCourseWare
**Procesamiento de Lenguaje Natural con
Aprendizaje Profundo,**
Máster en Ciencia y Tecnología Informática

**Tema 1.2. Tareas básicas para representación de
textos en aplicaciones de NLP**

Objetivos

- Comprender la necesidad de representar los textos para procesarlos.
- Conocer las principales técnicas para reducir la variabilidad de los textos.
- Estudiar los modelos tradicionales para la representación de textos, como el modelo bolsa de palabras y tf-idf.
- Conocer las ventajas y desventajas de estos modelos tradicionales.

Índice

- Representación de textos
- Modelos tradicionales:
 - bolsa de palabras
 - tf-idf.

Representación de textos, ¿qué es?

- Transformar un texto en un vector de números.

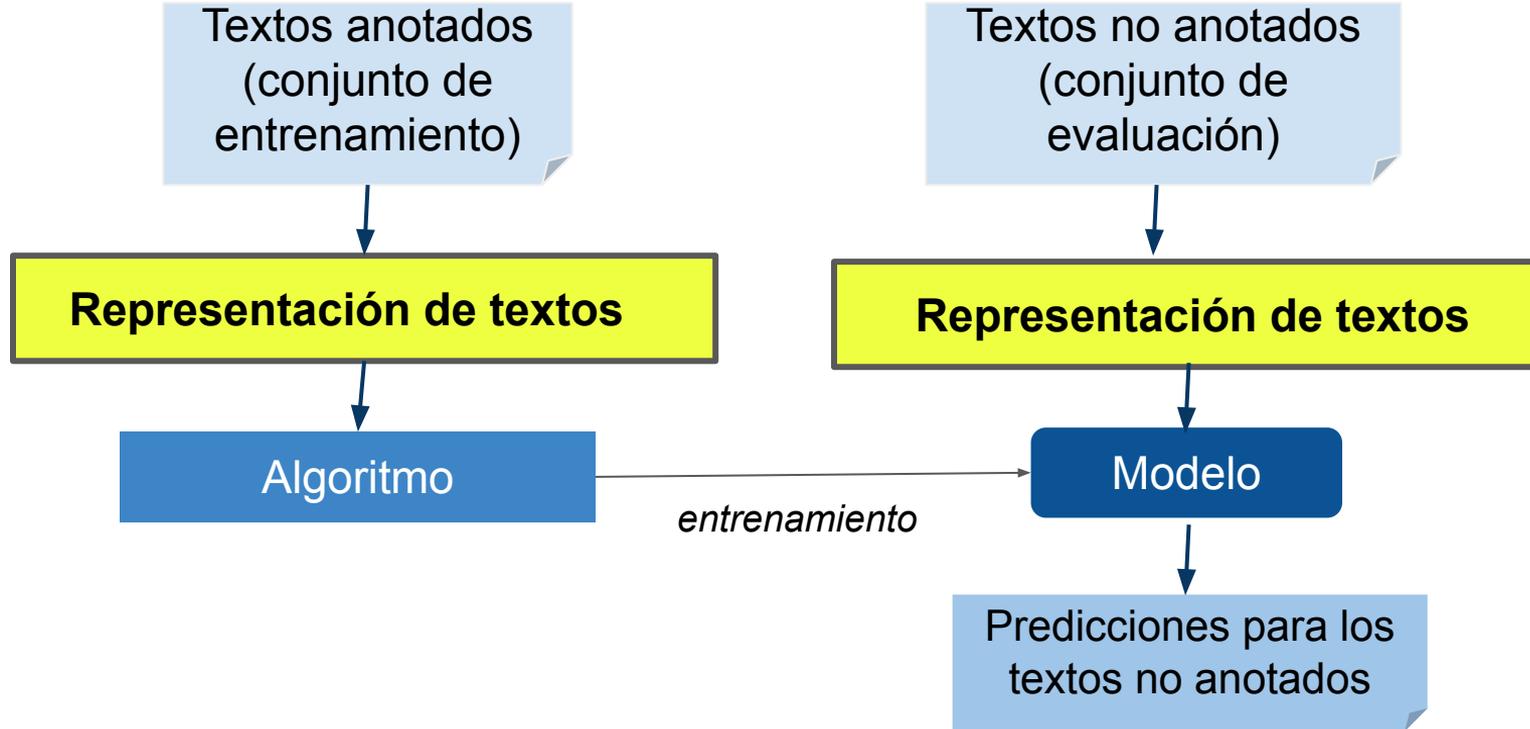
The big cat is on the table



ball	big	cat	moon	small	table	tree	...	zoo
0	1	1	0	0	1	0	...	0

- La dimensión del vector depende del tamaño del vocabulario (conjunto de palabras distintas en la colección de textos).

Arquitectura de un sistema PLN basado en de aprendizaje automático



Limpiar textos

- Antes de la transformación a vectores, es deseable realizar algunas **tareas** de limpieza que permitan **reducir la variabilidad del lenguaje**:
 - Transformar a minúsculas
 - Eliminar signos de puntuación, números, etc (puedes utilizar [patrones](#)).
 - Eliminar stopwords.
 - Lemmatización.
 - Stemming.

Stopwords

- Palabras más comunes en un idioma y que no añaden significado relevante al texto.
- Ejemplos de [stopwords en inglés](#): “the”, “is”, “in”, “for”, “where”, “when”, “to”, “at” etc.
- Ejemplos de [stopwords en español](#): de, que, el, en y, a, los, se, del, las, un, por, con, no una, etc.
- Eliminar stopwords es recomendable en algunas tareas de PLN como la clasificación de textos o recuperación de información.
- En un dominio concreto (por ejemplo, el dominio clínico) la lista de stopwords puede ser ampliada con palabras comunes en dicho dominio: paciente, médico, ambulancia, etc.

Stopwords

- Ventajas al eliminar stopwords:
 - Disminuye el tamaño del vocabulario.
 - Disminuye la dimensionalidad en modelos de representación como la bolsa de palabras o tf-idf.
 - Reduce ruido, el algoritmo se puede centrar en las palabras que sí aportan semántica al texto.
- Sin embargo, las stopwords no deben ser eliminadas en otras aplicaciones de PLN como la traducción automática o el reconocimiento de entidades.

Lematización

- Dada una palabra, la lematización consiste en devolver su lema o forma canónica (palabra que aparece en un diccionario).
- Ejemplos: *comió, comiendo, comeré, come* -> *comer*.
- Debe ser aplicada en aplicaciones de PLN como la clasificación de textos o recuperación de información:
- Ventajas:
 - Disminuye tamaño del vocabulario
 - Disminuye dimensionalidad en modelos de representación como la bolsa de palabras y tf-idf.
 - Reduce ruido.
- Varias librerías de PLN: ntlk, spacy.

Stemming

- Similar a la lematización, dada una palabra, devuelve su raíz.
- Basada en algoritmos como [Porter](#) o [Lancaster](#).
- Algunos ejemplos de reglas:
 - *SSES -> SS (caresses -> caress)*
 - *S -> (cats -> cat)*
 - *EED -> EE (agreed -> agree, feed -> feed)*
 - *ATOR -> ATE (operator -> operate)*
 - *ER -> (airliner -> airlin)*
- Stemming es más eficiente que la lematización, pero menos robusta. Ejemplos de errores: stories -> stori, leaves -> leav, horses -> hors, better -> better (debería ser good).

Índice

- Representación de textos
- Modelos tradicionales:
 - bolsa de palabras
 - tf-idf.

Modelos de representación de textos

- Una vez que el texto ha sido limpiado, es posible aplicar distintas técnicas para transformar los textos a vectores.
- Algunos de los enfoques más populares son:
 - Modelo de bolsa de palabras
 - Modelo tf-idf
 - Modelos word embedding (entrenados con redes de neuronas).

Índice

- Representación de textos
- Modelos tradicionales:
 - **bolsa de palabras**
 - tf-idf.

Modelo Bolsa de Palabras (Bag of Words, BoW)

- Dada una colección de textos (previamente limpiados), se obtiene su vocabulario.
- El **vocabulario** es el conjunto de todas las **palabras distintas** (sin incluir las repeticiones) de la colección de textos.
- En el vocabulario, las palabras están ordenadas alfabéticamente y **cada palabra es representada** con un número entero (**índice**), que indica su posición en el vocabulario.
- Cada **texto** puede ser **representado** como un **vector** cuya dimensión es el tamaño del vocabulario. Cada posición del vector representa una de las palabras del vocabulario.
- El valor asociado a cada posición del vector es el **número de veces que ocurre esa palabra en el texto**.

Modelo Bolsa de Palabras (Bag of Words, BoW)

Texto:

The big cat is on the table and the small cat in the window.

Texto limpio:

~~*The big cat is on the table and the small cat in the window.*~~

ball	big	cat	moon	small	table	tree	window	zoo
0	1	2	0	1	1	0	1	0

Modelo Bolsa de Palabras (Bag of Words, BoW)

D1: ~~The big cat is on the table~~ and ~~the small cat in the window~~

D2: ~~The table~~ and ~~the window~~ are small

D2: ~~The moon~~ and ~~the small tree~~ are big

	ball	big	cat	moon	small	table	tree	window	zoo
D1	0	1	2	0	1	1	0	1	0
D2	0	0	0	0	1	1	0	1	0
D3	0	1	0	1	1	0	1	0	0

Modelo TF-IDF

- Versión extendida del modelo bolsa de palabras.
- Cada texto es representado usando tf-idf de cada palabra en el vocabulario.
- Se utiliza **TF-IDF** porque consigue **disminuir** el **peso** de aquellas **palabras que son muy comunes** en la colección de textos.

TF-IDF

- Term frequency - inverse document frequency de la palabra w en el document d

$$\mathbf{TF-IDF}(w,d) = \mathbf{TF}(w,d) * \mathbf{IDF}(w)$$

- $\mathbf{TF}(w,d)$ = frecuencia de la palabra w en el documento d
- $\mathbf{IDF}(w)$ = *inverse document frequency*. Logaritmo del cociente entre el número total de documentos (N) y el número de documentos que contienen a la palabra w

$$IDF(w) = \log\left(\frac{N}{|d \in D: w \in d|}\right)$$

Bolsa de Palabra

	ball	big	cat	moon	small	table	tree	window	zo o
D1	0	1	2	0	1	1	0	1	0
D2	0	0	0	0	1	1	0	1	0
D3	0	1	0	1	1	0	1	0	0

TF-IDF

	ball	big	cat	moon	small	table	tree	window	zoo
D1	0	0.17	0.95	0	0	0.17	0	0.17	0
D2	0	0	0	0	0	0.17	0	0.17	0
D3	0	0.17	0	0.47	0	0	0.47	0	0

Ventajas de los modelos BoW y TF-IDF

- Fáciles de implementar.
- Buenos resultados en tareas de clasificación de textos.

Desventajas de los modelos BoW y TF-IDF

- Los vectores tienen una gran dimensionalidad (tamaño del vocabulario) y la información es escasa y dispersa (muchos 0s).
- No pueden capturar información semántica. Por ejemplo, estas dos expresiones tienen un significado similar, pero tendrán vectores diferentes:
 - *Edema de glotis != hinchazón de la laringe*

Desventajas de los modelos BoW y TF-IDF

- No tienen en cuenta la posición de las palabras. De esta forma, las dos siguientes oraciones son representadas con el mismo vector, pero sin embargo tienen significados opuestos:
 - *The hotel was very good and not expensive !=*
 - *The hotel was very expensive and not good*

Cómo implementar los modelos BoW y TF-IDF

- Aunque sería posible desarrollar ambos modelos paso a paso, afortunadamente, la librería [sklearn](#), ya hace este trabajo para nosotros y nos proporciona clases [CountVectorizer](#) para el modelo bolsa de palabras, y [TfidfVectorizer](#) para el modelo tf-idf.
- En el siguiente [link](#) puedes encontrar un ejemplo de cómo utilizar estas clases.

Resumen

- **PLN** basado en **aprendizaje automático** implica representación de **textos** (**transformación** a **vectores** de números).
- Aplicar técnicas para **reducir** la **variabilidad** del **lenguaje**.
- **Bolsa de palabras** y **tf-idf** basados en la **frecuencias** de las palabras en los textos.
- Son modelos **eficientes**.
- Sin embargo, presentan algunas limitaciones: **alta dimensionalidad** y su **imposibilidad** de capturar **información** 25 **semántica**.

OpenCourseWare
Procesamiento de Lenguaje Natural con
Aprendizaje Profundo,

Gracias!!!

<https://github.com/iseaura>