

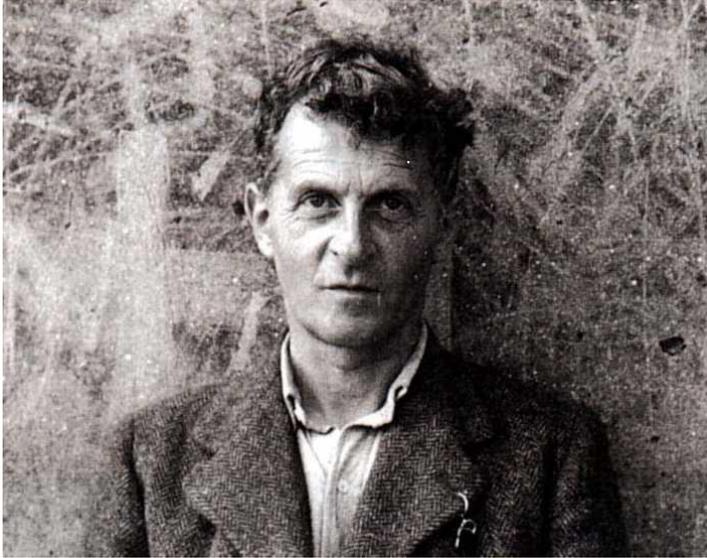
Laboratorio de datos, clase 20

Word embeddings con *word2vec*

Prof. Enzo Tagliazucchi

tagliazucchi.enzo@gmail.com

www.cocuco.org



“El significado deriva del uso de las palabras en el lenguaje”

Ludwig Wittgenstein

“Las palabras se definen por su compañía”

“Dime con que palabras apareces y te diré qué significas”

“Ítems lingüísticos con distribuciones similares tienen significados similares” (hipótesis distribucional)

	Palabra 1	Palabra 2	Palabra 3	Palabra 4	Palabra 5	
Relato 1	0	0.12	0.01	0	0	
Relato 2	0	0	0.44	0.15	0.65	
Relato 3	0.11	0.31	0.28	0	0	(...)
Relato 4	0	0	0.05	0.21	0	
Relato 5	0	0.13	0	0.07	0	
			(...)			

La correlación lineal entre filas nos da una idea de la similitud del significado entre relatos

La correlación lineal entre columnas nos da una idea de la similitud del significado entre palabras

Pero hay un problema: la mayor parte de los valores son 0

“Sobre la mesa hay un florero con margaritas y jazmines”

“El vaso lleno de flores está apoyado sobre una mesada”

**Significado muy similar,
ninguna palabra en común**

**Solución: próximas clases
(ya tenemos todas las herramientas)**

Idea

Reducir la dimensión del vocabulario, pasando de ~50.000 palabras a ~100, en una representación que ya no sea esparsa.

En el espacio original, cada dimension es una palabra y pueden variar independientemente. Pero sabemos que en realidad no es el caso: la dimension es menor, porque hay interacción entre las palabras.


Más aún, introducir una medida de distancia en este espacio de forma tal que *palabras con significado similar estén cerca*.


Word embedding

Vocabulario

Word2vec

Embedding





Para qué sirve

Encontrar similitud semántica entre palabras y entre documentos

Buscar las palabras que se parezcan más o menos a una dada

Operar con embeddings y buscar la palabra más cercana al resultado



Autocompletar frases

Agrupar palabras de significados similares

Buscar analogías entre palabras


Modelo semántico del lenguaje para comparar con procesamiento del lenguaje hecho por humanos

Biological Neuron versus Artificial Neural Network




Cada unidad de la ultima capa (gris) recibe una combinación lineal de los valores de cada unidad de entrada (azul), aplica una función, y obtiene un output (rojo)

El objetivo es encontrar los coeficientes de la transformación lineal que mejor reproduce los outputs obtenidos en un conjunto de entrenamiento




$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$



x_i


$$y_j = f\left(\sum w_{ji} x_i\right)$$


En este ejemplo,
 w_{ji} vive en $R^{3 \times 6}$



Skip-gram

Los inputs son palabras y los outputs palabras, ambas en one hot encoding.
Los samples de entrenamiento se generan poniendo una ventana alrededor de cada palabra y seleccionando todas las palabras dentro de ese contexto






Word embedding

Actualmente hay mejores métodos (globe, fasttext, etc)


Estas ideas claramente no se aplican solo a lenguaje



THE SIMPSONS™



¿Cual es el más distinto a los demás?



Unir con flechas

