

Detección de metáforas utilizando redes neuronales convolucionales

Ericka Deyanira Ovando-Becerril, Hiram Calvo-Castro

Instituto Politécnico Nacional,
Centro de Investigación en Computación,
Laboratorio de Ciencias Cognitivas Computacionales,
México

{eovandob2021, hcalvo}@cic.ipn.mx

Resumen. Este trabajo presenta una investigación sobre el estado del arte en la interpretación y generación de metáforas dentro del campo de la lingüística computacional. En la segunda sección, se muestran los resultados de un clasificador de lenguaje literal y no literal utilizando redes neuronales convolucionales (CNN) y redes neuronales multicapa (MLP). Finalmente, se presentan y comparan los resultados experimentales, destacando el rendimiento de los enfoques propuestos.

Palabras clave: Metáfora, lingüística computacional, procesamiento de lenguaje natural, lenguaje literal.

Metaphore Detection Using Convolutional Neural Networks

Abstract. This work presents an investigation regarding of the state of the art around the interpretation of metaphors and their respective generation in the computational linguistics topics. At second section, this work shows the results of literal and non-literal language classifier using convolutional neural networks and multilayer neural networks and finally the results are presented and compared as an experiment.

Keywords: Metaphor, computational linguistics, natural language processing, literal language.

1. Introducción

Este trabajo tiene como punto fundamental la detección de la metáfora; en particular, se busca proponer un acercamiento claro al concepto de metáfora, al estado del arte y a la experimentación en torno al tema central de este proyecto. Es relevante para esta investigación identificar claramente conceptos, trabajos y

áreas de oportunidad que conduzcan hacia una propuesta innovadora y funcional que represente una aportación dentro del campo de estudio.

En cuanto a la revisión del concepto de metáfora, se establecen algunos puntos fundamentales, particularmente dentro de las ciencias computacionales cognitivas. En el estado del arte se mencionan las propuesta más relevantes en torno al problema a tratar y se presentan los resultados de: un clasificador mediante redes neuronales convolucionales (CNN) y un clasificador por redes neuronales multicapa. A manera de aclaración se propuso este clasificador por su versatilidad dentro del procesamiento del lenguaje natural y la posibilidad de considerar la información del contexto. Como punto de referencia se considera el auge durante los últimos años del Deep learning en el procesamiento de lenguaje natural para diversas tareas desde traducción hasta análisis contextual. Siendo el Procesamiento del Lenguaje Natural la intersección de Ciencias Computacionales, la Lingüística y la Inteligencia Artificial.

La necesidad del hombre de comunicarse o representar su entorno, mas allá de las imágenes nos remite a la época primigenia. El concepto del lenguaje y de comunicación trasciende entre filósofos, lingüistas y pensadores a través de la historia pero también en épocas más recientes entre computólogos e ingenieros. En este contexto podemos considerar a Platón en el *Crátilo* o Aristóteles en su *Poética* como ejemplo de los primeros trabajos sobre esta temática. Entender la metáfora exige comprender [a grandes rasgos] el lenguaje; el lenguaje nos obliga a cuestionar la existencia de los signos y cuestionar la existencia de los signos significa cuestionar todo nuestro entorno, ahora bien, entender todo lo anterior como un complejo sistema a clasificar no es un problema menor dentro del Procesamiento del Lenguaje Natural (PLN).

Pensar en torno a la idea del signo, remite en automático a San Agustín (354-430) y a Occam (1285-1349), de esta forma podemos ir repasando de manera cronológica la concepción de las diversas ideas y conceptos sobre el lenguaje y la metáfora, trabajo que sería muy complicado de llevar a cabo. Por lo anterior, esta primera sección tiene como objetivo identificar las directrices de este proyecto y justificar su relevancia.

A partir del lenguaje como proceso de significación se han acuñado conceptos como: “imagen”, “signo”, “alegoría”, “símbolo”, “emblema”, “parábola”, “mito”, “figura”, “icono” y “metáfora”. A partir de la teoría de los signos de Ricoeur, se puede considerar las ideas de la metáfora muy cercanas al símbolo. La metáfora se concibe como una innovación semántica, un acontecimiento propio del discurso. De acuerdo con Cicerón y Quintiliano la metáfora es una comparación abreviada, y de acuerdo con Aristóteles en su *Poética* es “la aplicación de una cosa de un nombre ajeno, con lo que efectúa la transferencia de género a especie, de especie a género, de especie a especie, o existe una analogía, esto es una proposición. De manera concisa la analogía es una figura retórica donde la semejanza sirve para sustituir una palabra por otra. Partiendo de este concepto “tradicional” podemos comprender la metáfora como el ejercicio de extrapolar una palabra de una semántica a otra, sin embargo, a partir de este concepto, ya complicado por sí mismo, surge,

de acuerdo con [4] la metáfora conceptual; que no se limita a funcionar en un sistema signado sino que está presente en la manera que nosotros entendemos el mundo, las asociaciones que generamos de manera natural y en los diversos sistemas de signos que nos rodean. A este respecto es importante aclarar que la metáfora no se limita, en este trabajo, a un concepto de una imagen literaria o un recurso lingüístico sino a una estructura compleja que puede tener o no un carácter lingüístico, y que se convierte en objeto de estudio, de interpretación, y también en un objeto a generar.

La metáfora, de acuerdo con [4], representa entonces una idea “origen” y una idea “objetivo” la cual está sujeta al contexto cultural y lingüístico. Por ejemplo, la idea de la vida como un viaje que puede estar presente en frase, en una historia, o una canción, es una metáfora conceptual, que trasciende los límites lingüísticos donde la idea de “origen” es el viaje y la idea “objetivo” es la vida. Otros ejemplos podrían ser la actividad laboral como una competencia, la supervivencia como un juego, o el amor como un viaje.

Por supuesto, el concepto de la metáfora no sólo es cercano al símbolo sino también a la metonimia, donde la designación del significado cambia de acuerdo con el contexto.

La complejidad del propio sistema de la metáfora se robustece con la complejidad del sistema lingüístico, en consecuencia, es un complicado problema dentro de la ingeniería. La metáfora, por si misma, es un reflejo de nuestras habilidades creativas como humanos XVeale16 ¿Cómo imitar o replicar esto desde el cómputo o cómo entenderlo desde la Inteligencia Artificial?

Como se ha analizado de manera breve en este trabajo, la complejidad del problema a abordar es alta, la metáfora es mas que frases o sistemas de palabras, es una forma de pensamiento, la representación del sistema semántico, la identificación y clasificación es un reto, un problema computacional digno de abordar desde el Procesamiento del Lenguaje Natural y fundamental para el desarrollo de la Inteligencia Artificial.

2. Estado del arte

Los primeros proyectos sobre procesamiento del lenguaje natural (PLN) tuvieron un enfoque semántico, en el año 1975 XMason4. La búsqueda de la metáfora parte de los sistemas literatistas que tienen como base la identificación de del significado literal de una frase u oración para poder identificar las metáforas. Fue hasta 1979 que Aarts y Calbert utilizaron un marcador semántico, este sistema funciona a partir de cuatro características que englobaban principalmente el significado literal y el significado secundario. Retomando estos conceptos, Russell en 1992 desarrolla el sistema MAP, con características más específicas y tomando como referencia un diccionario semántico y el desarrollo de estructuras iniciales para expresiones metafóricas XVeale16.

Otra observación importante es que, a diferencia de los primeros algoritmos [6], en las propuestas de [11] y [12], la representación del diccionario semántico

no es mediante listas sino mediante un sistema de diccionarios que representan conceptos conectados por vértices bidireccionales. Aunque existen diversos trabajos realizados en torno a la detección y la generación de metáfora y en este proyecto será complicado mencionarlos todos, será de vital importancia para esta tesis realizar un análisis detallado de cada uno de ellos o en su caso de los más representativos, y poder enriquecer a partir de esto este proyecto. Como ya se ha mencionado, en la actualidad existen diversos autores y trabajos recientes que han realizado valiosas propuestas en torno a la detección de la metáfora, entre los mas representativos para este proyecto se consideran [12], [4], y [2] trabajos que resultan valiosos dentro de la clasificación de la metáfora, y se consideran un punto de partida para su estudio. Es importante mencionar que la interpretación y generación de metáforas que se tiene como objetivo final de este proyecto requiere primeramente de la evaluación de los posibles corpus disponibles para la tarea, el preprocesamiento, el modelo del algoritmo primeramente para su clasificación y posteriormente para la generación. De acuerdo a lo anterior es que se ha analizado el estado del arte.

Respecto a los corpus entre los mas mencionado en la literatura son TroFi, MOHnMOH-X y VUA, un referente para el estudio de metáfora en idioma ingles. Así mismo en muchos trabajos como referencia directa del análisis de metáfora se considera el contexto, y se utilizan como herramienta de apoyo WordNet y VerbNet. Un ejemplo es la clasificación de verbos.

Así mismo en torno al Procesamiento del Lenguaje Natural, se consideran a [5] y [1] para identificar las diversas estrategias de vectorización de un texto (word2vec, word vectors, embeddings etc...). Este material presenta el uso de Python para el PLN, y las bibliotecas: Keras, TensorFlow, NLTK y PyTorch como recursos importantes dentro de esta investigación.

Algunos otros trabajos no menos relevantes en torno a la tarea de detección de la metáfora son [8], [13], [7], [9], [3], los cuales proponen diversas soluciones, algunas de las mas recientes utilizando redes neuronales. Entre las herramientas que se identifican en los trabajos de los autores mencionados, para la clasificación de texto, se encuentran: redes neuronales, redes neuronales convoluciones, redes neuronales generativas, el algoritmo de Nave Bayes y redes neuronales recurrentes, en sus distintas configuraciones y combinaciones.

El trabajo en torno a la semántica de los diccionarios de metáfora se ha ido complejizando a la velocidad que el avance en los lenguajes de programación lo han permitido, trabajar [hoy en día] entendiendo estos sistemas semánticos metafóricos como sistemas interconectados permite una identificación y generación mas efectivas de la metáfora. Es importante mencionar que la clasificación de la metáfora se relaciona estrechamente con el contexto de la oración o texto que se está analizando.

Aunque existen varios trabajos en torno a la detección de la metáfora las áreas de oportunidad aún son muchas, la generalidad de respuesta de la mayoría de los algoritmos reportados es muy limitada. Los retos de la detección son tan amplios como el numero de idiomas en el mundo; sin

Tabla 1. Ejemplos de oraciones literal y no literal de Trofi Dataset del verbo absorber.

Lenguaje Literal	Lenguaje No literal
The Monitor's losses are absorbed by the church's working fund, which has declined during the past two years to about 200million from more than 280 million, largely because of the stock-market crash.	But in the short-term it will absorb a lot of top management's energy and attention, says Philippe Haspeslagh, a business professor at the European management school, Insead, in Paris.
The yellow beta carotene pigment absorbs blue -LRB- not yellow -RRB- laser light.	Mr. Wyss of Data Resources suggested that factories may be having difficulty hiring new workers at a time of such low unemployment or may simply not be able to absorb as many new workers as they would like.
This time, the ground absorbed the shock waves enough to transfer her images to the metal in bas-relief.	Now, do all of them absorb it and grab it?

embargo el aproximarnos a una solución viable representa un gran paso para el Procesamiento del Lenguaje Natural.

3. Desarrollo de la solución

3.1. Descripción de la solución al problema planteado

Para esta primera propuesta experimental se implementaron:

1. Una red neuronal convolucional que clasifica lenguaje no literal y lenguaje metafórico
2. Una red neuronal que clasifica lenguaje literal y lenguaje metafórico.

Se desarrolló a partir de Trofi Dataset XGaoGsa, compuesto por 2,146 oraciones metafóricas y 1593 oraciones literales de 51 verbos en inglés.

El preprocesamiento consistió en generar 4 grupos de oraciones:

1. Training data: Literal
2. Training data: No Literal
3. Taste: Literal
4. Taste: No literal

En todas las oraciones: Se eliminaron los signos de puntuación y las stopwords y se convirtió todo el texto a minúsculas. El modelo que se utilizó para la vectorización del corpus fue: bag to words.

Es importante mencionar que para ambas redes se tomaron de referencia los ejercicios presentados en [10]. Así mismo se consideraron como base los modelos

para la clasificación de lenguaje literal y no literal, [1], y [3], respectivamente. Para obtener estos resultados, se trabajó en Python 3.8.

El modelo de la CNN se desarrolló a partir de Pythorch y esta compuesta por tres filtros convolucionales; cada capa convolucional con su respectiva función ReLu y seguida por su función Max Pooling. Para minimizar el error se utilizó el gradiente. La entrada al clasificador está compuesto por vectores v de $[1 \times (\text{tamaño del vocabulario})]$ que corresponde a la representación de la oración a clasificar en un modelo vectorial bag to words.

La red neuronal de dos capas, se desarrolló a partir de Numpy. Se utiliza la función sigmoidea como base de las neuronas y se minimiza el error a partir de su derivada. La primera capa de neuronas consta de n neuronas, recibe la matriz de $n \times m$, donde m = número de oración del conjunto de datos de entrenamiento y n = tamaño del vocabulario. La segunda capa de este experimento se configuró para 30 neuronas.

Para ambos casos únicamente se tienen dos clases: Lenguaje literal y Lenguaje no literal o metafórico.

En este trabajo se presentan los resultados estadísticos de las redes propuestas y se analiza la viabilidad de ambas para solucionar el problema planteado en este documento y en un futuro proponer un algoritmo más robusto.

Estos dos ejercicios de experimentación resultan una propuesta interesante en primer lugar por los resultados preliminares obtenidos. Así mismo permiten plantear posibilidades y repensar el uso de herramientas de redes neuronales multicapa y redes neuronales profundas para proponer una solución más clara.

3.2. Evaluación

Para la evaluación de los clasificadores antes mencionados, se presenta la matriz de confusión para ambos casos, a partir de estos datos se consideran los siguientes parámetros:

$$Accuracy = \frac{TrueMetaphore + TrueLiteral}{TrueMetaphore + TrueLiteral + FalseMetaphore + FalseLiteral}, \quad (1)$$

$$Precisión(Metaphora) = \frac{TrueMetaphore}{TrueMetaphore + FalseMetaphore}, \quad (2)$$

$$Precisión(Literal) = \frac{TrueLiteral}{TrueLiteral + FalseLiteral}, \quad (3)$$

$$Recall = \frac{TrueMetaphore}{TrueMetaphore + FalseLiteral}. \quad (4)$$

Estos índices estadísticos nos permiten conocer el desempeño de los clasificadores y determinar mejoras a realizar.

4. Experimentos y resultados

Los experimentos realizados para la clasificación de metáfora se llevaron a cabo mediante dos clasificadores distintos: el primero, utilizando un clasificador de redes neuronales convolucionales, y el segundo, mediante un clasificador de redes neuronales multicapa. A continuación se presentan algunos ejemplos de oraciones y su clasificación en los cuadros 2 y 3.

Los resultados se presentan en los cuadros 4 y 5 respectivamente.

Tabla 2. Ejemplo de oraciones clasificadas con redes neuronales convolucionales.

		<i>Clasificación</i>	
		<i>Literal</i>	<i>No Literal</i>
<i>Clase</i>	<i>Literal</i>	Under the proposed merger Bush adds two women aides Wheelabrator Technologies will to address women's issues and absorb Waste Management's plans a big push on child care Tampa Fla incinerator and three stressing a menu of choices for other waste to energy projects parents. the company has under.	
	<i>No Literal</i>	The cooling off period ordered as They do it to cool off the market part of Mr Reagan s naming of a so to speak because they need presidential emergency board in the copper and when they're April to try to resolve the issue. buying they find themselves chasing.	

Tabla 3. Ejemplo de oraciones clasificadas por medio de redes neuronales multicapa

		<i>Clasificación</i>	
		<i>Literal</i>	<i>No Literal</i>
<i>Clase</i>	<i>Literal</i>	The Monitor's losses are Operations at metal and absorbed by the church's wood coffin manufacturing working fund which reportedly plants in Missouri Indiana and has declined during the past two Pennsylvania will remain open years to about 200 million from and in fact be expanded with more than 280 million largely additional shifts to absorb some because of the stock market of the workers and production crash. idled elsewhere	
	<i>No Literal</i>	Management of three of the While the rest of the nation five highest yielding general watched with mere curiosity or purpose funds as ranked by the slight concern the nation's Donoghue Organization absorb fourth largest city was a portion of fund expenses. thoroughly absorbed by the approach of Hurricane Gilbert	

Tabla 4. Matriz de confusión para el clasificador convolución

		<i>Clasificación</i>	
		Literal	Metafora
<i>Clase</i>	Literal	125	26
	Metáfora	78	31

Tabla 5. Matriz de confusión para el clasificador de redes neuronales multicapa

		<i>Clasificación</i>	
		Literal	Metáfora
<i>Clase</i>	Literal	79	20
	Metafora	22	77

Resultados estadísticos CNN. Una vez presentadas las matrices de confusión se observa para el caso del clasificador por redes neuronales convolucionales:

$$\begin{aligned}
 Accuracy &= 0.66 \\
 Precisión(Metáfora) &= 0.32 \\
 Precisión(Literal) &= 0.82 \\
 Recall &= 0.28
 \end{aligned}$$

Resultados estadísticos redes neuronales multicapa. Una vez presentadas las matrices de confusión se observa para el caso del clasificador de dos capas de redes neuronales:

$$\begin{aligned}
 Accuracy &= 0.79 \\
 Precisión(Metáfora) &= 0.77 \\
 Precisión(Literal) &= 0.79 \\
 Recall &= 0.79
 \end{aligned}$$

5. Conclusiones y trabajo futuro

Una vez realizada una primera aproximación sobre la detección de metáfora en este trabajo, es evidente la relevancia de la generación y la interpretación

de la metáfora dentro del área del Procesamiento del Lenguaje Natural, que a pesar de la existencia de valiosas propuestas, requiere de nuevos métodos para la obtención de mejores resultados.

Respecto a los resultados de la experimentación reportados en este documento, se ve claramente un mejor desempeño en la red neuronal multicapa. Como trabajo a futuro se considera muy importante evaluar los modelos con un preprocesamiento mas fino y una representación vectorial más robusta cómo la mencionada en [3].

Referencias

1. Antić, Z.: Python natural language processing cookbook : over 50 recipes to understand, analyze, and generate text for implementing language processing tasks. Birmingham Packt März (2021)
2. Bolognesi, M.: Metaphor and metonymy in the digital age. John Benjamins Publishing Company, (2019)
3. Gao, G., Choi, E., Choi, Y., Zettlemoyer, L.: CorMet: Neural metaphor detection in context. University of Washington, (2018)
4. Kövecses, Z.: Metaphor (2010)
5. Le, D., Thai, M., Nguyen, T.: Multi-task learning for metaphor detection with graph convolutional neural networks and word sense disambiguation. Proceedings of the AAAI Conference on Artificial Intelligence, vol. 34, pp. 8139–8146 (04 2020) doi: 10.1609/aaai.v34i05.6326
6. Masón, Z.: Cormet: Un sistema de extracción de metáforas convencional computacional y basado en corpus. Computational linguistics, (2004)
7. Maudslay, R., Pimentel, T., Cotterell, R., Teufel, S.: Metaphor detection using context and concreteness. University of Cambridge, (2020)
8. Minh Le, D., Thai, M., Huu, T.: Multi-task learning for metaphor detection with graph convolutional neural networks and word sense disambiguation. University of Florida, USA; University of Oregon, (2020)
9. Ruder, S., Vulić, I., Søgaard, A.: A survey of cross-lingual word embedding models. Journal of Artificial Intelligence Research, vol. 65, pp. 569–631 (08 2019) doi: 10.1613/jair.1.11640
10. Ugik: Text classification using neural networks (10 2017), <http://medium.com/@gk/text-classification-using-neural-networks-f5cd7b8765c6>
11. Veale, T., Keane, M. T.: The competence of sub-optimal theories of structure mapping on hard analogies. In: IJCAI (1). pp. 232–237. Citeseer (1997)
12. Veale, T., O'Donoghue, D.: Computation and blending, (2001)
13. Wilks, Y., Galescu, L., J., A., Dalton, A.: Automatic metaphor detection using large-scale lexical sources and conventional metaphor extraction. Florida Institute for Human and Machine Cognition,