

## Uso de red convencional de grafos para clasificar información no valida

### Use of conventional graph network to classify invalid information

DOI: 10.46932/sfjdv5n5-006

Received on: Apr 02<sup>nd</sup>, 2024

Accepted on: Apr 22<sup>nd</sup>, 2024

#### **Moisés García Villanueva**

Maestria en Ingeniería Eléctrica

Institución: Universidad Michoacana de San Nicolás de Hidalgo, Facultad de Ingeniería Eléctrica

Dirección: Av. Francisco J. Mújica S/N, C.P. 58030, Morelia Michoacán

Correo electrónico: moises.garcia@umich.mx

#### **Salvador Ramírez Zavala**

Maestria en Ingeniería Eléctrica

Institución: Universidad Michoacana de San Nicolás de Hidalgo, Facultad de Ingeniería Eléctrica

Dirección: Av. Francisco J. Mújica S/N, C.P. 58030, Morelia Michoacán

Correo electrónico: salvador.ramirez@umich.mx

#### **RESUMEN**

El poder que ha propiciado el Internet y las redes sociales a las personas de publicar contenido, que frecuentemente es parcial y no verificado, ha ocasionado la generación y propagación de noticias falsas. La problemática de propagar una desinformación, rumor o información mal intencionada, puede llegar a tener grandes daños en diferentes aspectos de la sociedad: económicos, de salud física, mental, por mencionar unos cuantos. El objetivo de este trabajo es presentar los resultados de implementar un modelo de Redes Convolucionales de Grafos para clasificar textos de noticias falsas de forma automática. Se presentan los resultados para un conjunto de datos balanceado y diferentes tamaños del conjunto de entrenamiento y prueba. Se concluye que esta técnica obtiene resultados competitivos a las del estado del arte de redes neuronales recurrentes para esta tarea.

**Palabras clave:** GCN, Redes Neuronales de Grafos, Clasificación de Texto, Noticias Falsas.

#### **ABSTRACT**

The power that the Internet and social networks have given people to publish content, which is frequently partial and unverified, has caused the generation and spread of fake news. The problem of spreading misinformation, rumors or ill-intentioned information can cause great damage to different aspects of society: economic, physical and mental health, to name a few. The objective of this work is to present the results of implementing a Convolutional Graph Networks model to classify fake news texts automatically. Results are presented for a balanced data set and different training and test set sizes. It is concluded that this technique obtains competitive results with the state of the art of recurrent neural networks for this task.

**Keywords:** GCN, Graph Neural Networks, Text Classification, Fake News.

## 1 INTRODUCCIÓN

La constante extensión de las redes sociales hoy en día, ha propiciado múltiples canales paralelos para que los usuarios cuenten con diversas facilidades versátiles para generar y obtener noticias, situación impensable hace unos cuantos años. Gracias a que las personas pueden beneficiarse del servicio y de la simple conveniencia de las redes sociales, en los trabajos de Auxier y Anderson (2021) y Silver (2019), se ha revelando que algunas noticias cautivadoras e incorrectas publicadas en las plataformas de las redes sociales particularmente tienen un contenido falso y de alto impacto en los países de economías emergentes y su entorno social. Estas historias de noticias falsas están compuestas intencionalmente para llevar información incorrecta como una especie de idea, como manipulación empresarial o gubernamental. La difusión de titulares falsos podría tener graves consecuencias para las personas y la cultura. Por lo tanto, identificar y manejar las noticias falsas se convierte en un obstáculo crítico dentro de los temas que se desarrollan en discusiones de las redes sociales actuales. El término "noticias falsas" se puede describir en diversas configuraciones que difieren ligeramente entre sí, pero la mayoría de las veces se pueden usar indistintamente por lo siguiente: desinformación, mentira, falsedad, engaño, broma, propaganda, enlaces web tendenciosos (click bait), conceptos erróneos, fabricación de un engaño, por mencionar unos cuantos.

En la actualidad utilizar los medios sociales para el consumo noticioso es una espada de doble filo. Por un lado, se ofrecen a un muy bajo costo, acceso fácil y difusión o distribución rápida. Por otro lado, conlleva el peligro que significa el exponerse a "noticias falsas" cuyo contenido es información mal verificada o incluso intencionalmente falsa y destinada a engañar y manipular a los lectores para que persigan determinadas agendas políticas o económicas. La amplia difusión de noticias falsas se ha convertido recientemente en un problema global y una amenaza para las democracias modernas. Por mencionar sólo dos ejemplos que propiciaron la necesidad de realizar investigaciones sobre las noticias falsas son: la amplia dispersión de noticias falsas antes de las elecciones presidenciales de 2016 en Estados Unidos; y la información vertida para la votación del Brexit en Reino Unido. El fenómeno de desinformación se convirtió en la pieza central de la controversia en torno a estos eventos políticos y que generó acusaciones de manipulación de la opinión pública. Debido al muy alto costo social y económico del fenómeno, en el último año, la detección de noticias falsas en las redes sociales ha atraído una enorme atención en los ámbitos académico e industrial.

La detección automática de noticias falsas plantea grandes desafíos y retos a los enfoques existentes y que se basan en el análisis de contenido. Una de las principales razones es que a menudo la interpretación de las noticias es muy matizada y requiere el conocimiento del contexto político o social, probablemente del "sentido común", que aún faltan incluso en los algoritmos de procesamiento del lenguaje natural más avanzados. Además, las noticias falsas son a menudo escritas intencionalmente por malos actores para que

aparezcan como noticias reales pero que contienen información falsa o manipuladora, dicha información tiene formas que son difíciles de detectar incluso para expertos humanos capacitados.

## 2 MARCO TEÓRICO

Los enfoques existentes para la detección de noticias falsas pueden dividirse en tres categorías principales: basados en: el contenido; el contexto social; y la propagación o difusión (Shu *et al.*, 2017; Vosoughi *et al.*, 2018; Zhou; Zafarani, 2020). Los enfoques basados en contenido, los cuales son los más utilizados en los trabajos que abordan esta tarea, tienen sus bases en las características lingüísticas (léxicas y sintácticas) en donde es posible identificar estilos de escritura. El principal inconveniente de los enfoques basados en contenido es que pueden ser eludidos por noticias falsas suficientemente sofisticadas que no aparecen inmediatamente como falsas. Además, la mayoría de las características lingüísticas dependen del idioma, limitando la generalidad de estos enfoques. Por otro lado, los enfoques basados en las características del contexto social incluyen los rasgos demográficos (edad, género, educación y afiliación política) (Shu *et al.*, 2018; Long 2017), la estructura de la red social (en la forma de conexiones entre los usuarios tales como relaciones entre amigos o seguidores) (Shu *et al.*, 2019; Shu-Bernard *et al.*, 2019) y reacciones de los usuarios como opiniones me gusta o disgusta (Tacchini *et al.*, 2017). Finalmente, los enfoques basados en la propagación son quizás la dirección de investigación más intrigante y prometedora basado en el estudio del proceso de proliferación de noticias a lo largo del tiempo. Se ha argumentado que el proceso de difusión de noticias falsas es similar a la propagación de enfermedades infecciosas (Kucharski 2016) y puede entenderse con modelos de epidemias en red. Existe evidencia empírica sustancial de que las noticias falsas se propagan de manera diferente a las noticias verdaderas formando patrones de difusión que podrían potencialmente ser explotados para la detección automática de noticias falsas.

## 3 REDES NEURONALES DE GRAFOS

En años recientes, las técnicas de aprendizaje profundo han tenido un impacto considerable en múltiples dominios, en particular en visión por computadora, análisis de voz y en procesamiento de lenguaje natural. Sin embargo, los modelos clásicos de redes neuronales profundas, tales como las redes neuronales convolucionales (CNNs por sus siglas en Inglés de Convolutional Neural Networks), están basadas en la teoría de procesamiento digital de señales, con un fundamento en los datos estructurados en forma matricial que subyace en un espacio euclidiano. En los últimos años, ha habido un interés creciente en generalizar las técnicas de aprendizaje profundo para datos no euclidianos (por ejemplo, los de estructuras de grafos). Los primeros enfoques para el aprendizaje en grafos (Scarselli *et al.*, 2008) son

anteriores al reciente renacimiento del aprendizaje profundo y se formulan como puntos fijos que emplean operadores de difusión que permiten el aprendizaje. Se ha hecho entonces el planteamiento de las redes neuronales de grafos y dentro de este grupo se cuenta con los modelos de las Redes Neuronales de Grafos (GCN por sus siglas en Inglés de Graph Neural Networks).

Un GCN (Kipf y Welling 2016) es una red neuronal multicapa que opera directamente sobre un grafo que induce vectores de encajes de nodos basados en las propiedades de sus nodos vecinos. Formalmente un grafo se define como  $G = (V, E)$ , donde  $V$  y  $E$  son conjuntos de nodos y aristas respectivamente. Cada nodo se asume que está conectado así mismo, representando esta conexión como  $(v, v) \in E$  para cualquier  $v$ . Sea  $X \in R^{n \times m}$  que representa una matriz conteniendo todos los  $n$  nodos con sus características, mientras que  $m$  es la dimensión del vector de características, cada renglón en la matriz,  $x_v \in R^m$ , es el vector de características para el nodo  $v$ . Se establece una matriz de adyacencia  $A$  para el grafo  $G$  y su matriz de grado  $D$ , donde  $D_{i,i} = \sum_j A_{i,j}$ . Los elementos de la diagonal de la matriz  $A$  tienen el valor de 1, por su conexión así mismo. GCN puede capturar solamente información acerca de los vecinos inmediatos por medio de una capa convolucional. Cuando múltiples capas en un GCN son apiladas, la información acerca de vecinos más alejados es integrada. Para una sola capa en la GCN, la nueva matriz de características de los nodos es de dimensión  $k$ ,  $L^{(1)} \in R^{n \times k}$  y se calcula mediante (1).

$$L^{(1)} = \rho(\mathcal{A} \times W_0) \quad (1)$$

dónde:

$\mathcal{A} = D^{-1/2} A D^{-1/2}$  es la matriz de adyacencia simétrica normalizada

$W_0 \in R^{m \times k}$  es una matriz de pesos.

$\rho$  función de activación, por ejemplo la función ReLU que se define como  $\rho(x) = \max(0, x)$ .

La función de activación  $\rho$ , incorpora información de orden superior de vecinos cercanos, implica apilar múltiples capas en el GCN, esto se representa por (2).

$$L^{(j+1)} = \rho(\mathcal{A} L^j W_j) \quad (2)$$

en donde

el subíndice  $j$  representa el número de capa y  $L^{(0)} = X$ .

## 4 PRUEBAS Y RESULTADOS

### 4.1 CONJUNTO DE DATOS

Se obtuvo un conjunto de datos de Bisailon (2019), del sitio de kaggle. Originalmente el conjunto de datos cuenta con un total de 44882 noticias, que después de eliminar las repetidas, el conjunto consiste de 37813 artículos noticiosos en el idioma Inglés. 16740 son noticias falsas y 21073 son reales o ciertas. El preprocesamiento de los textos consistió en convertir a minúsculas, considerar solamente palabras con una frecuencia mayor a 5, eliminar las palabras vacías, signos de puntuación y caracteres especiales. La longitud mínima de una noticia es de 24 palabras, mientras que la longitud máxima es de 5942 palabras. Debido a las limitaciones de infraestructura del poder de cómputo, se logró realizar pruebas con un conjunto de datos de máximo 13447 noticias. El equipo de cómputo con que se contó para el desarrollo del presente trabajo tiene un procesador core i5 y memoria ram de 16 GB.

### 4.2 PRUEBAS

Pruebas; Se implementó la GCN de Yao (*et al.*, 2019) para la clasificación de noticias falsas, utilizando los siguientes parámetros para entrenar el modelo: tamaño de los vectores de encajes de dimensión 200, tamaño de ventana de 20, tasa de aprendizaje = 0.2 y dropout = 0.5.

Se realizaron 3 pruebas para responder la misma cantidad de preguntas en la obtención de un modelo con un buen desempeño. La primer prueba consistió en utilizar diferentes cantidades de documentos para el entrenamiento y prueba, la finalidad es responder el planteamiento de la siguiente pregunta:

¿Puede una GCN obtener buen rendimiento con una cantidad pequeña de datos?

La segunda prueba fue variar la cantidad de épocas en la etapa de entrenamiento del modelo, la pregunta planteada para esta prueba fue:

¿Cuál es la cantidad de épocas de entrenamiento del modelo para lograr un buen rendimiento?

Finalmente, la tercer prueba consistió en variar la cantidad de neuronas ocultas en la primer capa convolucional, la finalidad de la prueba es dar respuesta a la pregunta:

¿Se puede establecer una cantidad de neuronas mínima para la primer capa convolucional en la GCN?

La métrica reportada en los resultados es la precisión, definida por (2).

$$E = \frac{P_C}{N_{TP}} \quad (1)$$

dónde:

$P_C$  es la cantidad de predicciones correctas del modelo

$N_{TP}$  es el número total de predicciones

### 4.3 RESULTADOS

En la primera prueba se utilizaron 5000 y 13447 noticias para mostrar evidencia del efecto que se tiene al emplear diferentes cantidades de documentos en el entrenamiento del modelo. El Cuadro 1 muestra los resultados de desempeño empleando diferentes cantidades de documentos para el conjunto de entrenamiento y de prueba.

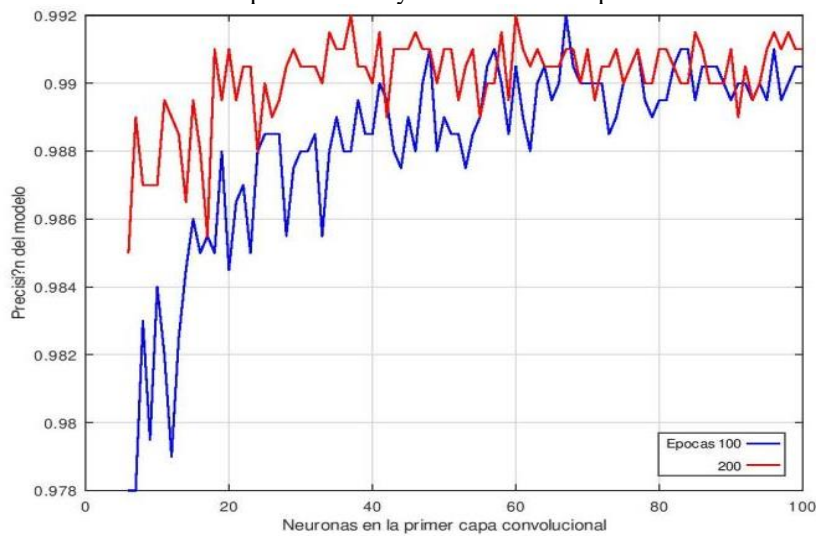
Cuadro 1. Resultados de desempeño del modelo empleando diferentes cantidades de documentos de noticias para el entrenamiento y prueba de la GCN.

5000 documentos			13447 documentos		
Entrenamiento	Prueba	Precisión (%)	Entrenamiento	Prueba	Precisión (%)
4000	1000	99.2	10758	2689	97.28
3500	1500	98.53	9413	4034	96.82
3000	2000	98.13	8068	5379	96.54

Fuente: Elaboración propia

Para dar respuesta a las preguntas 2 y 3, en la Figura 1 se presenta el comportamiento de desempeño del modelo al ir incrementando la cantidad de unidades en la primer capa de la GCN. Se observa un incremento de la precisión del modelo a medida que este incrementa la cantidad de neuronas en la primer capa, llegando a un punto en donde se mantiene sin mejorar su desempeño. Para el caso de 100 épocas de entrenamiento se logra llegar el mejor resultado de desempeño utilizando 64 unidades con una precisión del 99.2%, mientras que para 200 épocas de entrenamiento este mismo resultado de desempeño del modelo se logró en dos ocasiones, con 37 y 60 unidades en la primer capa de la GCN.

Figura 1. Desempeño del modelo para diferentes cantidades de unidades en la primera capa de la GCN. Se muestran los casos para 100 y 200 épocas de entrenamiento del modelo sobre un conjunto con 5000 documentos, utilizando una relación de 80% de datos para entrenar y 20% de datos de prueba.



Fuente: Elaboración propia

La gráfica en la Figura 1 indica que a mayor tiempo o ciclos de entrenamiento del modelo se logra llegar al mejor desempeño con una cantidad menor de neuronas en la primera capa de entrada de la GCN, la implicación de este resultado deriva en la obtención de un modelo más pequeño que requiere menores recursos de cómputo. Además, con un mayor tiempo de entrenamiento se observa que se obtiene un mejor desempeño.

## 5 CONCLUSIONES

El presente trabajo presenta evidencia empírica del desempeño de una red convolucional de grafos en la clasificación de noticias falsas. Para el conjunto de 5000 noticias, se observó que una mayor cantidad de ciclos de entrenamiento nos proporciona un mejor desempeño del modelo, logrando un 99.2% cuando la cantidad de documentos para entrenar es del 80% y para prueba es del 20%, concluyendo que esta relación es la que proporcionó un mejor comportamiento en el desempeño del modelo. La diferencia en el desempeño cuando la relación de particionar los datos para entrenar y probar es 70-30 es de 0.67 para el caso de 5000 documentos y de 0.46 para el conjunto de 13447, menor a un punto porcentual, concluyendo que se cuenta con un margen considerable para obtener un modelo que pueda satisfacer las necesidades de desempeño. A una mayor cantidad de datos el modelo tiene mayores dificultades para clasificar los textos, eso se evidencia con el conjunto de 13447 documentos, en donde la precisión sufre una caída de aproximadamente 2% respecto a los mejores valores de desempeño obtenidos en ambos conjuntos de datos. En el trabajo de Mathur (2020) se reporta una precisión de 99.87% utilizando una red neuronal recurrente y encajes de vectores preentrenados para la clasificación, por lo que se concluye que un modelo de GCN obtiene resultados competitivos a los mejores resultados empleando este conjunto de datos.



## REFERENCIAS

- Auxier, B. & Anderson, M. (2021). *Social media use in 2021*. Pew Research Center.
- Bisaillon C. *Fake and real news dataset: Classifying the news*. URL: <https://www.kaggle.com/clmentbisaillon/fake-and-real-news-dataset>. 2019
- Kucharski, A. (2016). Study epidemiology of fake news. *Nature*, 540(7634), 525-525.
- Long, Y. (2017). *Fake news detection through multi-perspective speaker profiles*. Association for Computational Linguistics.
- Mathur M. *NLP using GloVe Embeddings (99.87% Accuracy)*. Recuperado em <https://www.kaggle.com/madz2000/nlp-using-glove-embeddings-99-87-accuracy/data>. Último acceso el 04/11/2021.
- Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M. & Monfardini, G. (2008). The graph neural network model. *IEEE transactions on neural networks*, 20(1), 61-80.
- Shu, K., Bernard, H. R. & Liu, H. (2019). Studying fake news via network analysis: detection and mitigation. In *Emerging research challenges and opportunities in computational social network analysis and mining* (pp. 43-65). Springer, Cham.
- Shu, K., Sliva, A., Wang, S., Tang, J. & Liu, H. (2017). Fake news detection on social media: A data mining perspective. *ACM SIGKDD explorations newsletter*, 19(1), 22-36.
- Shu, K., Wang, S. & Liu, H. (2018, April). Understanding user profiles on social media for fake news detection. In *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)* (pp. 430-435). IEEE.
- Shu, K., Wang, S. & Liu, H. (2019, January). Beyond news contents: The role of social context for fake news detection. In *Proceedings of the twelfth ACM international conference on web search and data mining* (pp. 312-320).
- Silver L (2019). *Misinformation and fears about its impact are pervasive in 11 emerging economies*. Pew Research Center.
- Tacchini, E., Ballarin, G., Della Vedova, M. L., Moret, S. & de Alfaro, L. (2017). *Some like it hoax: Automated fake news detection in social networks*. arXiv preprint arXiv:1704.07506.
- Vosoughi, S., Roy, D. & Aral, S. (2018). The spread of true and false news online. *Science*, 359(6380), 1146-1151.
- Yao, L., Mao, C. & Luo, Y. (2019, July). Graph convolutional networks for text classification. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 33, No. 01, pp. 7370-7377).
- Zhou, X. & Zafarani, R. (2020). A survey of fake news: Fundamental theories, detection methods, and opportunities. *ACM Computing Surveys (CSUR)*, 53(5), 1-40.