

Aprendizaje de representaciones en grafos y su importancia en el análisis de redes



MARCELO MENDOZA Profesor Asociado del Departamento de Informática de la Universidad Técnica Federico Santa María e Investigador Asociado del Instituto Milenio Fundamentos de los Datos.

Una de las líneas de investigación en inteligencia artificial más fructíferas de la última década es el aprendizaje de representaciones. Mostraremos dos ejemplos en los cuales el aprendizaje de representaciones de nodos en grafos ha permitido abordar exitosamente tareas de análisis de redes.

DetECCIÓN DE *bots*

Los *bots* tienen un nefasto efecto en la diseminación de información engañosa o tendenciosa en redes sociales [1]. Su objetivo es amplificar la alcanzabilidad de campañas, transformando artificialmente mensajes en tendencias. Para ello, las cuentas que dan soporte a campañas se hacen seguir por cuentas manejadas por algoritmos. Muchas de las

cuentas que siguen a personajes de alta connotación pública son *bots*, las cuales entregan soporte a sus mensajes con *likes* y *retweets*. Cuando estos mensajes muestran un inusitado nivel de reacciones, se transforman en tendencias, lo cual aumenta aún más su visibilidad. Al transformarse en tendencias, su influencia en la red crece, produciendo un fenómeno de bola de nieve.

La detección de *bots* ha sido una tarea difícil. Mientras que las primeras generaciones de *bots* eran sencillas de detectar, las nuevas generaciones de *bots*, conocidas como *social bots*, alternan periodos de propaganda y periodos de baja actividad [2]. En estos últimos, los *bots* muestran un comportamiento cercano al de un usuario promedio, con participación esporádica en la red. En periodos de campaña, la actividad de estas cuentas aumenta.

El cambio en el régimen de interacciones es una pista que nosotros usamos para detectarlos.

En [3], mostramos cómo extender una representación de nodos aprendida a partir de la red de conexiones sociales en Twitter. La estrategia de aprendizaje usada se denomina ComplEx [4], la cual permite aprender *node embeddings* de la red de conexiones para predicción de *links*. Para capturar el régimen de interacciones entre cuentas, extendemos ComplEx reescalando los *node embeddings* en la dirección de los vecinos con los cuales tienen más interacciones. La Figura 1 muestra la estrategia de reescalamiento basada en interacciones, lo cual permite recalculer los *node embeddings* combinando ambas redes (social e interacción). Para aprender los *node embeddings* usamos una estrategia denominada *retrofitting* [5], que busca una

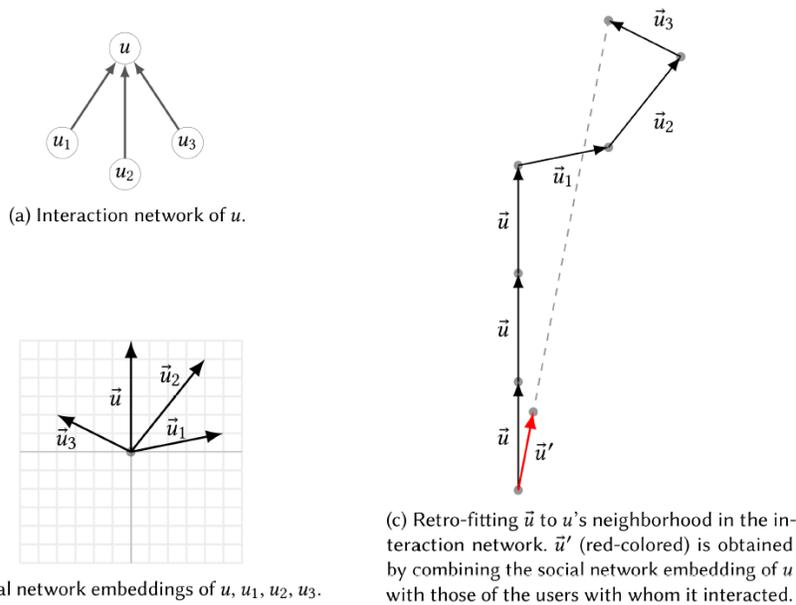


Figura 1. Extensión de ComplEx [4] que incorpora la red de interacciones entre usuarios de Twitter.

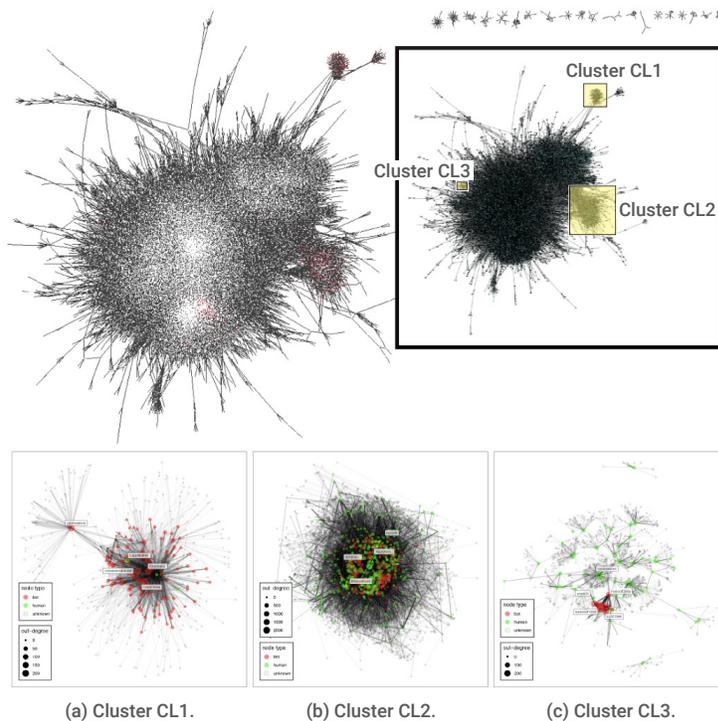


Figura 2. Red de proximidad entre *node embeddings* en Twitter, que muestra tres *clusters* con presencia de *bots* (nodos rojos). Mientras que el *cluster 1* (CL1) no logra interactuar con humanos (nodos verdes), los *clusters 2* (CL2) y 3 (CL3) se mimetizan, promoviendo contenido propagandístico.

representación consistente entre ambas fuentes de información.

Para detectar *bots*, aplicamos un algoritmo de propagación de etiquetas en la red de proximidad de *node embeddings*. El método de propagación permite trabajar con un número reducido de nodos etiquetados como *bots*, usando una estrategia semisupervisada sobre la red. La estrategia semisupervisada permite que el método funcione sobre redes de enorme tamaño con sólo una fracción de sus nodos etiquetados por expertos (app. 1% del total de la red). Mostramos que el método de imputación de etiquetas es análogo a una estrategia de paso de mensajes en una red neuronal de grafos que aborda una tarea de clasificación de nodos [6].

Nuestro método superó al estado del arte (Botometer [7] y Hologscope [8]). Su principal habilidad está en la detección de *botnets*, lo cual le permite sacar ventaja de sus más directos competidores que abordan la tarea como clasificación de nodos. El método de propagación de etiquetas tiene la ventaja de identificar grupos de cuentas *clusterizadas* según interacciones inusuales, detectando patrones de coordinación temporal. La Figura 2 muestra una red de proximidad entre *node embeddings* y tres *clusters* con alta presencia de *bots* (nodos rojos) en Twitter. Mientras que el *cluster 1* (CL1) es una *botnet* que no ha logrado interactuar con humanos (nodos verdes), los *clusters 2* (CL2) y 3 (CL3) muestran una mimetización de los *bots* en las redes de humanos, con interacción cruzada entre ambos tipos de usuarios.

Predictibilidad en redes sociales offline

En [9], analizamos las relaciones filiales entre personas, observables a través de los vínculos de apellidos paternos-ma-

ternos. La red construida con los datos del servicio electoral y cruzada con datos del Índice de Bienestar Territorial nos permitió construir un mapa de las conexiones familiares de los habitantes de la Región Metropolitana. Usando el método de Mateos *et al.* [10], identificamos los vínculos cuyas ocurrencias superaban el valor esperado dado por una red de conexiones aleatorias. Una vez construida la red, visualizamos su estructura agrupando nodos según modularidad. Las comunidades detectadas muestran etnias y también una fuerte *clusterización* de apellidos de clase alta según índice socioeconómico (ver Figura 3, al tope).

La misma red, ahora *clusterizada* según ingreso socioeconómico (ver Figura 3, al medio), muestra dos particiones, una con una fuerte interacción entre apellidos poco frecuentes y muchos nodos articuladores (comunidad azul de los tres deciles de ingreso más alto), y una partición mucho más desarticulada, con una vinculación más débil entre apellidos y menos nodos articuladores (comunidad roja de los siete deciles más bajos de ingreso). Estudiamos la predictibilidad de esta red, donde la tarea corresponde a predecir vínculos entre familias no conectadas (*link prediction*). Para hacer esto, aplicamos una técnica de aprendizaje de representaciones de nodos basada en factorización tensorial denominada método de Tucker [11]. Probamos el desempeño de otros métodos de representación a nivel de nodos, como Complex [4], RESCAL [12] y RotatE [13], usados en *knowledge-base completion*. Tucker mostró mejor desempeño en *link prediction* que sus competidores, factor atribuible a su habilidad de trabajar con datos *sparse*.

Al pie de la Figura 3 mostramos los resultados de predicción de vínculos segmentados por decil de ingreso. Los deciles de mayor ingreso (d1 - d3) muestran mejor predictibilidad, la cual disminuye progresivamente para los deciles de menor ingreso (d4 - d10).

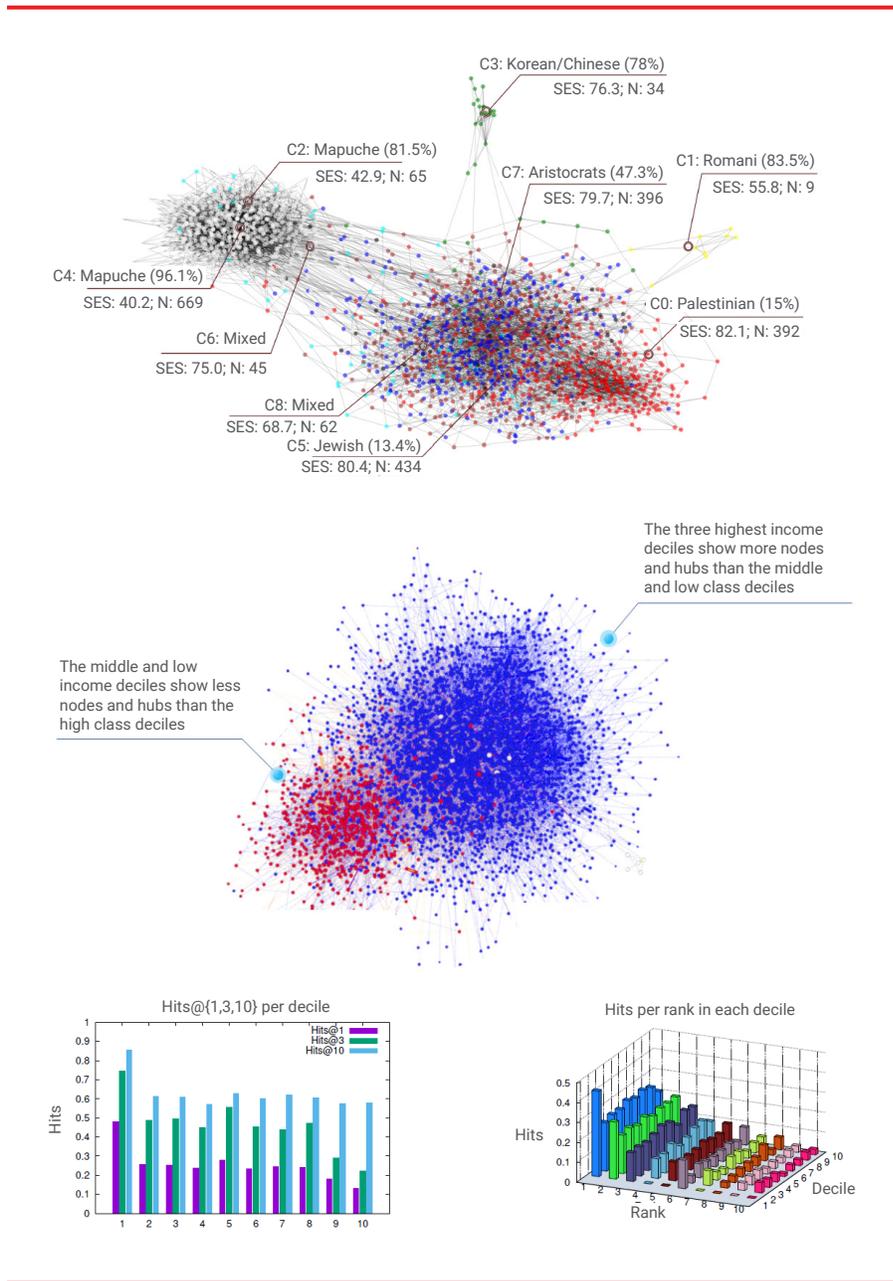


Figura 3. Redes de vínculos paternos-maternos en la Región Metropolitana (al tope), la misma red *clusterizada* según ingreso socioeconómico (al medio), y la predictibilidad de vínculos usando Tucker [11] (al pie).

Conclusión

La inteligencia artificial a través de su área denominada aprendizaje de representaciones ofrece enormes posibilida-

des en tareas complejas, tanto en redes sociales en línea como en redes *offline*. Su habilidad para codificar características esenciales en distintos dominios permite generar representaciones que mejoran las posibilidades de análisis de datos. ■

REFERENCIAS

- [1] Stefano Cresci: A decade of social bot detection. *Commun. ACM* 63(10): 72–83 (2020).
- [2] Stefano Cresci, Roberto Di Pietro, Marinella Petrocchi, Angelo Spognardi, Maurizio Tesconi: The Paradigm-Shift of Social Spambots: Evidence, Theories, and Tools for the Arms Race. *WWW (Companion Volume) 2017*: 963–972.
- [3] Marcelo Mendoza, Maurizio Tesconi, Stefano Cresci: Bots in Social and Interaction Networks: Detection and Impact Estimation. *ACM Trans. Inf. Syst.* 39(1): 5:1–5:32 (2020).
- [4] Théo Trouillon, Johannes Welbl, Sebastian Riedel, Éric Gaussier, Guillaume Bouchard: Complex Embeddings for Simple Link Prediction. *ICML 2016*: 2071–2080.
- [5] Manaal Faruqi, Jesse Dodge, Sujay Kumar Jauhar, Chris Dyer, Eduard H. Hovy, Noah A. Smith: Retrofitting Word Vectors to Semantic Lexicons. *HLT-NAACL 2015*: 1606–1615.
- [6] Franco Scarselli, Sweah Liang Yong, Marco Gori, Markus Hagenbuchner, Ah Chung Tsoi, Marco Maggini: Graph Neural Networks for Ranking Web Pages. *Web Intelligence 2005*: 666–672.
- [7] Onur Varol, Emilio Ferrara, Clayton A. Davis, Filippo Menczer, Alessandro Flammini: Online Human-Bot Interactions: Detection, Estimation, and Characterization. *ICWSM 2017*: 280–289.
- [8] Shenghua Liu, Bryan Hooi, Christos Faloutsos: HoloScope: Topology-and-Spike Aware Fraud Detection. *CIKM 2017*: 1539–1548.
- [9] Naim Bro, Marcelo Mendoza. Surname affinity in Santiago, Chile: A network-based approach that uncovers urban segregation. *PLOS ONE*, 16(1): e0244372, 2021.
- [10] Pablo Mateos, Paul Longley, David O’Sullivan. Ethnicity and population structure in personal naming networks. *PLOS ONE*, 6(9): e22943, 2011.
- [11] Ivana Balazevic, Carl Allen, Timothy M. Hospedales: TuckER: Tensor Factorization for Knowledge Graph Completion. *EMNLP/IJCNLP (1) 2019*: 5184–5193.
- [12] Maximilian Nickel, Volker Tresp, Hans-Peter Kriegel: A Three-Way Model for Collective Learning on Multi-Relational Data. *ICML 2011*: 809–816
- [13] Zhiqing Sun, Zhi-Hong Deng, Jian-Yun Nie, Jian Tang: RotatE: Knowledge Graph Embedding by Relational Rotation in Complex Space. *ICLR 2019*.