

# Métodos y Algoritmos para Procesamiento Distribuido de Grafos Masivos y Evolutivos

Tomás Delvechio<sup>1</sup>, Andrés Giordano<sup>1</sup>, Gabriel H. Tolosa<sup>1,2</sup>

{tdelvechio, agiordano, tolosoft}@unlu.edu.ar

<sup>1</sup>Departamento de Ciencias Básicas, Universidad Nacional de Luján

<sup>2</sup>CIDETIC, Universidad Nacional de Luján

## Resumen

El desafío de representar datos en entornos digitales posee gran interés frente a la masiva adopción de Tecnologías de la Información por parte de las poblaciones a escala mundial. Estas representaciones cobran importancia central y las estructuras elegidas condicionan los algoritmos y métodos que se usan para su procesamiento. Los grafos (o redes) son una estructura de datos que permite gran expresividad de representación, han sido ampliamente estudiados y existen algoritmos bien conocidos para su procesamiento. Sin embargo, en un entorno de datos masivos aparecen retos que en muchos casos no admiten soluciones triviales. La escalabilidad y optimización de los algoritmos de procesamiento de redes son motivo de incesante trabajo. Decisiones como particionar la estructura en varios subgrafos, generar índices que resuman la información para realizar estimaciones o procesar cambios de la red a través del tiempo afectan de formas diversas los tiempos de cálculo de algunas métricas (ejemplo, de centralidad, distancias, etc.) o la necesidad de almacenamiento. En este plan se propone analizar cómo es posible combinar/rediseñar varias de estas técnicas para obtener ventajas en entornos distribuidos o en el contexto nativo en que se ejecutan estos procesos, estudiar cómo son afectados los recursos según las decisiones de diseño a adoptar y realizar pruebas para conjuntos de datos de composición y tamaños heterogéneos.

**Palabras clave:** grafos, procesamiento distribuido, grafos dinámicos, estimación.

## Contexto

Esta presentación se encuentra enmarcada en el proyecto de investigación “Estrategias y Algoritmos para Problemas de Búsquedas a Gran Escala” (Dis-

posición CD-CB N° 350/19) del Departamento de Ciencias Básicas (UNLu).

## Introducción

La disponibilidad de información digital en escala global genera un constante interés en estrategias para su representación y procesamiento. Sin mucho esfuerzo resulta trivial obtener acceso a ingentes cantidades de datos a costos bajos o nulos. Un caso de interés son los datos que forman redes (*linked-data*) y que se modelan utilizando una de las representaciones más versátiles y utilizadas en computación: los grafos o redes [15].

Los nodos de un grafo<sup>1</sup> pueden representar infinitud de conceptos y las aristas expresan relaciones entre los nodos. De aquí, diferentes áreas en las ciencias y la tecnología trabajan cotidianamente con algoritmos de grafos, dada esta versatilidad y poder de abstracción.

Un cambio ocurrido en los últimos años es el crecimiento en el tamaño de los grafos que representan diferentes objetos de estudio (por ejemplo, Facebook reportaba que su grafo social contaba con millones de nodos y miles de millones de aristas para el 2015 [7]). A este escenario se le agrega que algunas aplicaciones requieren realizar consultas con severas restricciones de tiempo. Aparece entonces un problema cuando se consideran grafos masivos y es que ciertos algoritmos ‘*clásicos*’ dejan de ser competitivos por no poder responder en tiempos adecuados.

Otra característica que complejiza el tratamiento de estas estructuras es su dinámica. Hoy en día, existen grafos provenientes de sistemas que evolucionan constantemente, agregando nuevos nodos y

---

<sup>1</sup>En general, se suele definir un grafo como  $G = (V, E, w)$ , donde  $V$  es un conjunto de nodos,  $E$  es un conjunto de aristas que vinculan 2 nodos  $(v_i, v_j)$  donde  $v_i, v_j \in V$  y  $w$  es un vector de pesos para cada arista  $e_i \in E$ .

aristas en tiempo real, generando grafos dinámicos o evolutivos [13]. Por ello, su versatilidad para representar relaciones y el constante crecimiento en cuanto a tamaño y complejidad genera constante interés en el desarrollo de estrategias para su procesamiento eficiente.

Uno de los aspectos más interesantes de los grafos es que se pueden estudiar muchas propiedades a partir de las conexiones, sin considerar el significado intrínseco de sus componentes. Esto es, no importa si los nodos representan personas en una red social o routers en una red de datos; se pueden analizar y estudiar algunos comportamientos a partir de los nodos y sus enlaces. Un caso de estudio donde este enfoque es aplicado con notable éxito es en el estudio de la web y los algoritmos de análisis de enlaces utilizados para el ranking de las páginas en los motores de búsqueda [3]. En estos casos, una propiedad ampliamente estudiada (como el grado de los nodos) es utilizada como medida de reputación a la hora de reordenar los resultados [16].

Además de la distribución de grado, otras métricas y algoritmos son utilizados en las ciencias de la computación para el estudio de propiedades de los grafos. Por ejemplo, el camino más corto entre dos nodos. De estos algoritmos, cuyas propuestas conocidas suelen ser de orden de complejidad no lineales, surgen métricas importantes, como por ejemplo medidas de centralidad, utilizadas ampliamente en el análisis de redes sociales [12], donde se establece algún tipo de importancia a diferentes vértices en relación a la cantidad de caminos más cortos que pasan por éste [5]. En muchos casos, estos requerimientos obligan a realizar un procesamiento distribuido del grafo, requiriendo versiones de los algoritmos clásicos adaptadas a ejecutarse en un cluster de computadoras siendo, en general, problemas que no son trivialmente paralelizables dada la naturaleza lineal de la estructura de datos. Un ejemplo de esto es Betweenness Centrality, una medida de centralidad a partir de SSSP<sup>2</sup>, que asigna un ranking de importancia a los nodos en función de la cantidad de caminos que lo atraviesan [12]. Una opción al procesamiento distribuido para el cálculo exacto de ciertas métricas, es la generación de un índice que resume la información del grafo para estimar estos valores [17] [3] [2]. El objetivo principal de este enfoque es lograr la mejor calidad posible en este ‘resumen’ de tal manera que el error de estimación

sea el menor posible. En estos casos siempre existe un trade-off entre el costo de almacenamiento de esta estructura y la calidad de la estimación de las métricas. Luego, como método adicional para reducir aún más el error, las estimaciones pueden ser corregidas si existe alguna función que modele el comportamiento dependiendo de la técnica que se use para estimar.

Como se mencionó, una línea de trabajo desarrolla la problemática de estudiar grafos dinámicos o evolutivos. La idea de que el grafo evoluciona en el tiempo en cuanto a sus componentes agrega una complejidad desafiante que es tema de estudio en la actualidad [9][10]. Dado que existen métricas que se calculan para una versión inicial del grafo en un instante, se considera de interés estudiar cómo es posible calcular las métricas para una nueva versión de la estructura sin tener que procesar todo el grafo completamente. Esta idea resulta relevante principalmente en grafos masivos y métricas computacionalmente costosas, en los cuales el cómputo eficiente proviene solo de procesar las novedades [14] [1].

## Líneas de I+D

En este trabajo se describen líneas de I+D del grupo, las cuales se basan, principalmente, en desarrollar estrategias y analizar *trade-offs* existentes entre diferentes métodos de procesamiento (exactos y aproximados), sobre estrategias distribuidas en clusters de *commodity hardware*, con las consiguientes ventajas y desventajas que estos escenarios presentan. De forma continua aparecen nuevos desafíos en estas áreas y oportunidades de investigación en temas ya explorados por la comunidad científica. En particular, las líneas de I+D principales son:

### a. Cálculo Distribuido en Grafos Evolutivos

Diversos algoritmos que se aplican sobre grafos son ampliamente utilizados en la industria y la academia para abordar un gran abanico de soluciones. Algunos de estos algoritmos son los de camino más corto (Single Source Shortest Path o SSSP y All-Pairs Shortest Path o APSP), y suelen constituir la base de muchos procesos en ámbitos como la recuperación de información [6] o análisis de redes sociales [4], por nombrar un par de ejemplos.

Este tipo de procesos suelen tener soluciones aceptadas desde hace mucho tiempo, las cuales no

---

<sup>2</sup>Single Source Shortest Path

escalan cuando el tamaño de los datos supera un umbral, dando lugar a soluciones en tiempos no triviales [8]. Por otro lado, es todo un desafío la implementación de estrategias que aprovechen las características distribuidas de las plataformas existentes [10]. Otro problema que presentan los enfoques secuenciales tradicionales y no escalables es que muchas aplicaciones exigen de forma creciente respuestas cada vez más instantáneas, lo que introduce la posibilidad de construir soluciones aproximadas en el resultado pero eficientes en el tiempo insumido. También resulta importante considerar que los grafos, al representar relaciones, pueden cambiar a lo largo del tiempo, que se conoce como grafos dinámicos [11], y admiten soluciones que tengan en cuenta procesamientos previos para no tener que recalcularse completamente las métricas ante cada modificación del mismo.

Otro aspecto para lograr esta escalabilidad es tener esquemas de procesamiento parciales de la estructura de datos. Una estrategia conocida es el particionado del grafo (*divide-and-conquer*), que consiste en dividirlo en porciones más pequeñas (subgrafos) para poder procesarlo de forma distribuida. Esta estrategia ha sido ampliamente adoptada en los últimos años dado los tamaños de los grafos provenientes de servicios digitales [7] y las restricciones en cuanto a tiempos de respuesta. Los algoritmos de partición de grafos persiguen diversos objetivos, aplicaciones y complejidad lo que lleva a esquemas que utilizan diferentes heurísticas, suposiciones y restricciones [1]. Esto dificulta su comparación por lo que la selección de la técnica adecuada para un caso puntual es no trivial.

Dentro del marco del proyecto, el objetivo de esta línea de trabajo es diseñar y analizar algoritmos distribuidos sobre grafos dinámicos masivos considerando el *tradeoff* entre diferentes modelos de actualización de los datos (snapshots vs stream) considerando además esquemas de particionamiento adecuados.

## b. Estimación de Distancia entre Nodos

El problema de la distancia entre dos nodos tiene múltiples aplicaciones prácticas, por ejemplo, para el ranking en búsquedas en redes sociales o profesionales<sup>3</sup> o, como se mencionó, el ranking de resultados de un motor de búsqueda<sup>4</sup>. A esta métrica se la define

como la longitud del camino más corto entre dos nodos y se vuelve inviable si se requiere responder en pocos milisegundos en un grafo masivo. Esta distancia es usada en numerosos algoritmos que apuntan a resolver problemas como la recomendación de links [18] y agrupamiento de usuarios [9], entre otros.

El cálculo exacto de esta métrica entre dos nodos arbitrarios se ve afectado en cuanto a la eficiencia del proceso debido al tamaño de los grafos actuales resultando prohibitivo para aplicaciones prácticas. Por ejemplo, en redes sociales digitales el número de relaciones (aristas) supera ampliamente la cantidad de usuarios (nodos)<sup>5</sup>.

La estimación de este valor es una alternativa válida y la reducción del error asociado (a un costo computacional bajo) conforma una de las líneas de investigación de este proyecto. En este enfoque se utiliza un conjunto de nodos, llamados *landmarks* [17], que se toman como referencia para estimar luego la distancia entre dos nodos arbitrarios. El problema de la selección de *buenos landmarks*, es decir, aquellos que permitan minimizar el error de estimación, es una pregunta abierta ya que existen diversos criterios a aplicar que consideran grafos de diferente tamaño, densidad y dinámica. Algunos resultados preliminares sobre nuevos métodos de selección de *landmarks* indican que usar métricas tradicionales en conjunto (*Closeness Centrality* o *Degree*, entre otras), sobre ciertos grafos, potencian la estimación de la distancia logrando mejores resultados respecto del uso individual de éstas.

El desarrollo de métodos de corrección de la distancia estimada no ha sido abordado hasta el momento y es otra de las líneas de investigación de este proyecto. La idea consiste en lograr un algoritmo que, basado en características generales del grafo (como la densidad, diámetro, tamaño de comunidades, entre otras) permita corregir el valor de la estimación. Algunos resultados preliminares obtenidos por nuestro grupo sobre los mismos grafos estudiados en otros trabajos de referencia indican que es posible reducir el error de forma significativa mediante esta técnica.

<sup>5</sup>Twitter: 321 millones de usuarios activos, 226.947 millones de vínculos. <http://investor.twitterinc.com/home/default.aspx>

<sup>3</sup>Un caso es la red de contactos profesionales LinkedIn.

<sup>4</sup><https://patents.google.com/patent/US9165040B1/en>

## Resultados y objetivos

El objetivo principal de esta propuesta es desarrollar, evaluar y transferir algoritmos y estrategias para abordar algunas de las problemáticas relacionadas con el procesamiento de grafos masivos en entornos de clusters. En general, se proponen mejoras que apuntan a la eficiencia en la distribución de trabajo y la escalabilidad. En particular, se espera alcanzar los siguientes objetivos:

- Definir y evaluar estructuras y modelos de cómputo distribuido sobre clusters de *hardware commodity* para problemas de escalabilidad en el cálculo exacto de métricas sobre grafos masivos.
- Considerar y analizar el impacto en el rendimiento y escalabilidad de utilizar estrategias de procesamiento para grafos masivos evolutivos. De forma similar, analizar el efecto de utilizar técnicas de particionado en estos entornos distribuidos.
- Diseñar y estudiar estrategias de estimación de distancias entre nodos de un grafo masivo para problemas de búsqueda.
- Diseñar y estudiar estrategias de corrección de la estimación de distancias entre nodos de un grafo masivo.

## Formación de Recursos Humanos

En el marco de estas líneas de investigación se está dirigiendo una tesis de Licenciatura en Sistemas de Información (UNLu). Además, asociados al proyecto de investigación hay una estancia de investigación de la Secretaría de CyT (UNLu) y se espera contar con un becario de doctorado UNLu y al menos un pasante en 2020.

## Referencias

- [1] Z. Abbas, V. Kalavri, P. Carbone, and V. Vlasov. Streaming graph partitioning: an experimental study. *Proceedings of the VLDB Endowment*, 11(11):1590–1603, 2018.
- [2] T. Akiba, T. Hayashi, N. Nori, Y. Iwata, and Y. Yoshida. Efficient top-k shortest-path distance queries on large networks by pruned landmark labeling. In *Twenty-Ninth AAAI Conference on Artificial Intelligence*, 2015.
- [3] T. Akiba, Y. Iwata, and Y. Yoshida. Dynamic and historical shortest-path distance queries on large evolving networks by pruned landmark labeling. In *Proceedings of the 23rd international conference on World wide web*, pages 237–248, 2014.
- [4] D. A. Bader, S. Kintali, K. Madduri, and M. Mihail. Approximating betweenness centrality. In *International Workshop on Algorithms and Models for the Web-Graph*, pages 124–137. Springer, 2007.
- [5] U. Brandes. A faster algorithm for betweenness centrality. *Journal of mathematical sociology*, 25(2):163–177, 2001.
- [6] S. Brin and L. Page. The anatomy of a large-scale hypertextual web search engine. 1998.
- [7] A. Ching, S. Edunov, M. Kabiljo, D. Logothetis, and S. Muthukrishnan. One trillion edges: Graph processing at facebook-scale. *Proceedings of the VLDB Endowment*, 8(12):1804–1815, 2015.
- [8] A. Crauser, K. Mehlhorn, U. Meyer, and P. Sanders. A parallelization of dijkstra’s shortest path algorithm. In *International Symposium on Mathematical Foundations of Computer Science*, pages 722–731. Springer, 1998.
- [9] J. Edachery, A. Sen, and F. J. Brandenburg. Graph clustering using distance-k cliques. In *International Symposium on Graph Drawing*, pages 98–106. Springer, 1999.
- [10] N. Edmonds, T. Hoefer, and A. Lumsdaine. A space-efficient parallel algorithm for computing betweenness centrality in distributed memory. In *2010 International Conference on High Performance Computing*, pages 1–10. IEEE, 2010.
- [11] D. Ferone, P. Festa, A. Napoletano, and T. Pastore. Shortest paths on dynamic graphs: a survey. *Pesquisa Operacional*, 37(3):487–508, 2017.
- [12] L. C. Freeman. A set of measures of centrality based on betweenness. *Sociometry*, pages 35–41, 1977.

- [13] A. Kosmatopoulos, K. Giannakopoulou, A. N. Papadopoulos, and K. Tsihlias. An overview of methods for handling evolving graph sequences. In *International Workshop on Algorithmic Aspects of Cloud Computing*, pages 181–192. Springer, 2015.
- [14] A. McGregor. Graph stream algorithms: a survey. *ACM SIGMOD Record*, 43(1):9–20, 2014.
- [15] M. Newman. *Networks*. Oxford university press, 2018.
- [16] L. Page, S. Brin, R. Motwani, and T. Winograd. The pagerank citation ranking: Bringing order to the web. Technical report, Stanford InfoLab, 1999.
- [17] M. Potamias, F. Bonchi, C. Castillo, and A. Gionis. Fast shortest path distance estimation in large networks. In *Proceedings of the 18th ACM conference on Information and knowledge management*, pages 867–876, 2009.
- [18] Y. Zhang and J. Pang. Distance and friendship: A distance-based model for link prediction in social networks. In *Asia-Pacific Web Conference*, pages 55–66. Springer, 2015.