

Interseção de Vizinhança em Grafos via Amostragem de P_3

Vinícius M. Ribeiro¹, André L. Vignatti¹

¹Departamento de Informática – Universidade Federal do Paraná (UFPR)
Curitiba – PR – Brasil

{vmr20, vignatti}@inf.ufpr.br

Abstract. *Neighborhood intersection is a fundamental metric in social network analysis and data mining, and plays a central role in the computation of similarity metrics and measures. In this paper, we propose an efficient randomized algorithm, using P_3 sampling, to compute the neighborhood intersection for all combinations of pairs of vertices in a graph. With probability at least $1 - \delta$, we ensure that all approximations of the algorithm are at most ϵ away from their true value. We apply techniques from computational learning theory to obtain a sample size independent of any quantitative property of the graph.*

Resumo. *A interseção de vizinhança é uma métrica fundamental em análise de redes sociais e mineração de dados, e desempenha um papel central no cálculo de métricas e medidas de similaridade. Nesse artigo, propomos um algoritmo aleatorizado eficiente, utilizando amostragem de P_3 , para calcular a interseção de vizinhança para todas as combinações de pares de vértices em um grafo. Com probabilidade de pelo menos $1 - \delta$, garantimos que todas as aproximações do algoritmo estão a uma distância de no máximo ϵ de seu valor real. Aplicamos técnicas da teoria de aprendizado computacional para obter um tamanho de amostra independente de qualquer propriedade quantitativa do grafo.*

1. Introdução

A *interseção de vizinhança* de dois vértices em um grafo é definida como $|N(u) \cap N(v)|$, onde $N(u)$ e $N(v)$ são as vizinhanças dos vértices u e v , respectivamente. Ela desempenha um papel central no cálculo de métricas e medidas de similaridade [Easley and Kleinberg 2010, Newman 2010, Menczer et al. 2020]. Muitas métricas estabelecidas (como similaridade de cosseno, sobreposição de vizinhança e equivalência estrutural) são baseadas em versões normalizadas da interseção de vizinhança. Por isso, versões normalizadas podem ser de maior interesse do que a métrica não normalizada. A normalização é útil, pois fornece valores relativos ao grafo, que podem ser mais informativos do que medidas absolutas [Ribeiro and Vignatti 2025]. Neste artigo, introduzimos a interseção da vizinhança P_3 -normalizada, uma nova normalização para a interseção da vizinhança. A desnormalização dessa métrica, que permite obter resultados diretos para a métrica original, pode ser realizada com técnicas de Ribeiro e Vignatti [Ribeiro and Vignatti 2025], mas não será tratada aqui devido a limitações de espaço. Apresentaremos um algoritmo para determinar, para todos os pares de vértices de um grafo, o tamanho da interseção de vizinhança normalizada, baseado na amostragem de caminhos P_3 . Ao contrário das abordagens tradicionais que utilizam amostragem de estruturas mais simples, como vértices e arestas [Ribeiro and Vignatti 2025], nossa técnica explora a amostragem de uma estrutura mais complexa, resultando em um algoritmo mais eficiente. Desenvolvemos um método de amostragem uniforme e eficiente

de P_3 , um desafio não trivial em comparação com a amostragem de vértices ou arestas, que pode ser de interesse geral. Além disso, aplicamos técnicas avançadas de amostragem da teoria do aprendizado computacional para determinar limitantes rigorosos para o número de amostras necessárias, garantindo parâmetros de erro e confiança desejados. Embora a computação exata de interseção de vizinhança seja pouco estudada, existem métodos aproximados, como os de Besta et al. [Besta et al. 2021, Besta et al. 2022] para interseções únicas (apenas um par de vértices). Além disso, Ribeiro e Vignatti [Ribeiro and Vignatti 2025] abordam o problema de interseção de vizinhança de todos os pares, alcançando tempo $O(\Delta \log \Delta + |E|)$ em sua melhor estratégia, onde Δ é o grau máximo do grafo $G = (V, E)$. No mesmo cenário, nossa abordagem de amostragem de P_3 apresenta um tempo de execução de $O(|E|)$, demonstrando maior eficiência teórica e justificando a relevância do presente trabalho.

2. Preliminares

Seja $G = (V, E)$ um grafo não direcionado. Um P_3 é definido como sendo três vértices $\{u, v, w\}$ que possuem as arestas $\{u, v\}$ e $\{v, w\}$. \mathbb{P}_3 é o conjunto de todos os P_3 de G .

Definição 1. A *interseção da vizinhança* $i(u, v)$ de dois vértices u e v é a quantidade de vizinhos em comum de u e v , e.g. $i(u, v) = |N(u) \cap N(v)|$.

Conforme explicado na Seção 1, a normalização dos valores $i(u, v)$ não apenas gera resultados úteis, mas também enriquece o seu significado. Neste trabalho, focamos no cálculo de uma versão normalizada específica, apresentada na Definição 2.

Definição 2. A *interseção da vizinhança P_3 -normalizada* $i_{P_3}(u, v)$ do par de vértices u, v é dada por $i_{P_3}(u, v) = \frac{i(u, v)}{|\mathbb{P}_3|}$.

Os valores $i_{P_3}(u, v)$ representam o quão expressiva é a interseção da vizinhança de um par de vértices u, v , independente de qualquer propriedade do grafo. Se $i_{P_3}(u, v) = 1$, então u e v compartilham a maior quantidade possível de vizinhos. Se $i_{P_3}(u, v) = 0$, então u e v não compartilham nenhum vizinho.

Quando desejamos estimar múltiplos valores simultaneamente, a estratégia comum envolve a obtenção de limitantes individuais usando desigualdades probabilísticas clássicas, como as de Chernoff e Hoeffding, e, em seguida, a combinação desses limitantes individuais para obter um limitante global desejado através do limitante da união. Uma desvantagem dessa abordagem é que o limite da união leva a um tamanho de amostra que depende da quantidade de valores que se deseja estimar. A dimensão Vapnik-Chervonenkis (VC), proveniente da teoria de aprendizagem computacional [Shalev-Shwartz and Ben-David 2014], oferece um método mais refinado, limitando o tamanho da amostra com base na “complexidade” do conjunto de valores, em vez de sua cardinalidade. A seguir, apresentamos definições e teoremas a respeito desse assunto.

Um *espaço de intervalos* (X, \mathcal{R}) consiste em um conjunto X e uma família \mathcal{R} de subconjuntos de X . A *projeção* de $A \subseteq X$ em \mathcal{R} é $P_{\mathcal{R}}(A) = \{A \cap R : R \in \mathcal{R}\}$. Um conjunto A é *estilhado* por \mathcal{R} se $P_{\mathcal{R}}(A) = 2^A$. A *dimensão VC* de um espaço de intervalo (X, \mathcal{R}) , denotado $d_{VC}(\mathcal{R})$, é o tamanho do maior conjunto $A \subseteq X$ estilhado por \mathcal{R} . Para uma explicação mais aprofundada da dimensão VC, veja [Shalev-Shwartz and Ben-David 2014].

Definição 3. Seja (X, \mathcal{R}) um espaço de intervalo com uma distribuição de probabilidade π sobre X , $p_R = \Pr_{\pi}(R)$ a probabilidade de um intervalo $R \in \mathcal{R}$, e \hat{p}_R a frequência

relativa de R com base em uma amostra S . Para $\epsilon \in (0, 1)$, S é uma ϵ -aproximação para (X, \mathcal{R}) se $|\hat{p}_R - p_R| \leq \epsilon, \forall R \in \mathcal{R}$.

Teorema 1 ([Har-Peled and Sharir 2011], Teo. 2.12). *Seja (X, \mathcal{R}) um espaço de intervalo com dimensão VC $d_{VC}(\mathcal{R}) \leq d$, e seja π uma distribuição de probabilidade em X . Para $\epsilon, \delta \in (0, 1)$, e uma amostra S de tamanho m extraída de π , com probabilidade pelo menos $1 - \delta$, S é uma ϵ -aproximação de (X, \mathcal{R}) se $m \geq \frac{c}{\epsilon^2} (d + \ln \frac{1}{\delta})$, onde c é uma constante positiva.*

Por limitações de espaço, as provas dos teoremas serão omitidas neste trabalho e apresentadas em sua respectiva versão estendida.

3. Estimativa Usando Amostragem de P_3

Esta seção apresenta a nossa estratégia para estimar as interseções normalizadas $i_{P_3}(u, v)$.

3.1. Espaço de Intervalos e Resultados de Dimensão VC

A quantidade de amostras necessárias ao algoritmo baseia-se no resultado do Teorema 1, que, por sua vez, utiliza os valores da dimensão VC de um espaço de intervalos definidos para o problema. Abordaremos esse assunto a seguir.

Seja \mathbb{P}_3 o espaço amostral e $E_{P_3}(u, v)$ o evento em que uma amostra P_3 pertence à interseção das vizinhanças de u e v . Temos que

$$\Pr(E_{P_3}(u, v)) = \frac{|N(u) \cap N(v)|}{|\mathbb{P}_3|} = i_{P_3}(u, v),$$

onde a última equação segue da Definição 2. Assim, ao amostrar caminhos P_3 , aproximamos $i_{P_3}(u, v)$ estimando a probabilidade de $E_{P_3}(u, v)$. Seja $(\mathbb{P}_3, \mathcal{R}_{P_3})$ um espaço de intervalos, onde \mathcal{R}_{P_3} é o conjunto de todos os eventos $E_{P_3}(u, v)$ para $u, v \in V$, i.e., $\mathcal{R}_{P_3} = \{E_{P_3}(u, v) \mid u, v \in V\}$. O Teorema 2 limita a dimensão VC de $(\mathbb{P}_3, \mathcal{R}_{P_3})$.

Teorema 2. *A dimensão VC de $(\mathbb{P}_3, \mathcal{R}_{P_3})$ é $d_{VC}(\mathcal{R}_{P_3}) = 1$ se $|\mathbb{P}_3| \geq 1$, e 0 caso contrário.*

3.2. Algoritmo

Como discutido na seção anterior, para calcular a interseção da vizinhança de u e v $i_{P_3}(u, v)$, podemos estimar a probabilidade do evento $E_{P_3}(u, v)$. Utilizamos a frequência relativa de $E_{P_3}(u, v)$ para definir o nosso estimador $\hat{i}_{P_3}(u, v)$, i.e.,

$$\hat{i}_{P_3}(u, v) = \frac{1}{m} \sum_{i=1}^m \mathbb{1}_{E_{P_3}(u, v)}(s_i),$$

onde $\mathbb{1}_{E_{P_3}(u, v)}(s_i)$ é uma variável indicadora que assume 1 se $s_i \in E_{P_3}(u, v)$ e 0 caso contrário. Note que $\hat{i}_{P_3}(u, v)$ é um estimador não enviesado para $i_{P_3}(u, v)$, ou seja, $\mathbb{E}[\hat{i}_{P_3}(u, v)] = i_{P_3}(u, v)$. Tendo definido $i_{P_3}(u, v)$ e $\hat{i}_{P_3}(u, v)$ como a probabilidade de um evento e sua frequência relativa, respectivamente, podemos construir uma ϵ -aproximação (Definição 3) para $(\mathbb{P}_3, \mathcal{R}_{P_3})$. Formalmente, nosso algoritmo satisfaz,

$$\Pr\left(\forall u, v \in V, \left|i_{P_3}(u, v) - \hat{i}_{P_3}(u, v)\right| \leq \epsilon\right) \geq 1 - \delta.$$

Ou seja, com probabilidade pelo menos $1 - \delta$, o Algoritmo 1 garante que as estimativas para *todos* os pares de vértices estejam dentro de um erro máximo de ϵ em relação aos seus valores reais.

Algoritmo 1: INTERSEÇÃOVIZINHANÇAALÉATORIZADO(G, ϵ, δ)

Entrada: Grafo $G = (V, E)$, precisão ϵ , confiança $1 - \delta$

Saída : Estimativa $\hat{i}_{P_3}(u, v)$ para todo par $u, v \in V$

$m \leftarrow \lceil \frac{c}{\epsilon^2} (1 + \ln \frac{1}{\delta}) \rceil$

for $i \leftarrow 1$ **to** m **do**

$\{u, x, v\} \leftarrow \text{AMOSTRAR}P_3(G)$

$\hat{i}_{P_3}(u, v) \leftarrow \hat{i}_{P_3}(u, v) + \frac{1}{m}$

return $\hat{i}_{P_3}(u, v)$ para todos os pares $u, v \in V$

Teorema 3. *Dado um grafo $G = (V, E)$, parâmetros ϵ e δ , as estimativas $\hat{i}_{P_3}(u, v)$ retornadas pelo Algoritmo 1 satisfazem $\Pr \left(\forall u, v \in V, \left| i_{P_3}(u, v) - \hat{i}_{P_3}(u, v) \right| \leq \epsilon \right) \geq 1 - \delta$.*

O tempo de execução do Algoritmo 1 depende do tempo de execução da função AMOSTRAR P_3 , que será apresentado na Seção 3.3.

3.3. Amostragem Uniforme de P_3

Nesta seção, descrevemos um método para amostrar uniformemente um P_3 de um grafo G . Para cada aresta $e = \{u, v\} \in E$, definimos $p_e = \frac{d_u + d_v - 2}{2|\mathbb{P}_3|}$, onde d_u e d_v são os graus dos vértices u e v , respectivamente. A amostragem com pesos p_e pode ser feita usando o método Alias [Walker 1974] em tempo $O(|E|)$ para pré-processar os dados do grafo, e $O(1)$ para fazer cada amostragem. O Algoritmo 2 descreve o processo.

Algoritmo 2: AMOSTRAR $P_3(G)$

Entrada: Grafo $G = (V, E)$

Saída : Um P_3 amostrado uniformemente de \mathbb{P}_3

1. Amostre uma aresta $e = \{u, x\}$ com probabilidade p_e .
 2. Amostre um vértice v de $N(u) \cup N(x) \setminus \{u, x\}$ uniformemente.
 3. Retorne o caminho $\{u, x, v\}$.
-

Para definir os valores p_e no Passo 1, é necessário saber $|\mathbb{P}_3|$. O Lema 4 fornece um resultado útil para esse propósito.

Lema 4. *O número total de P_3 no grafo G é dado por $|\mathbb{P}_3| = \sum_{\{u,v\} \in E} \frac{d_u + d_v - 2}{2}$.*

O Teorema 5 mostra a corretude e o tempo de execução do Algoritmo 2. O tempo de execução, em particular, é baseado no método Alias e no Lema 4.

Teorema 5. *O Algoritmo 2 é de tempo $O(|E|)$ e amostra uniformemente um P_3 de \mathbb{P}_3 .*

Finalmente, usando os resultados apresentados, podemos enunciar o Teorema 6.

Teorema 6. *O tempo de execução do Algoritmo 1 é $O(|E|)$.*

4. Considerações Finais

Propomos um algoritmo que computa a interseção normalizada entre todos os pares de vértices com erro ϵ e probabilidade $1 - \delta$. Seu tempo de execução é $O(|E|)$, sendo mais eficiente do que outros no mesmo cenário. Ele utiliza amostragem de P_3 , que acaba sendo o gargalo do tempo de execução, e métodos mais eficientes de amostragem, como MCMC (Monte Carlo via Cadeias de Markov), podem ser explorados no futuro.

Referências

- Besta, M., Kanakagiri, R., Kwasniewski, G., Ausavarungnirun, R., Beránek, J., Kanellopoulos, K., Janda, K., Vonarburg-Shmaria, Z., Gianinazzi, L., Stefan, I., Luna, J. G., Golinowski, J., Copik, M., Kapp-Schwoerer, L., Di Girolamo, S., Blach, N., Konieczny, M., Mutlu, O., and Hoefler, T. (2021). Sisa: Set-centric instruction set architecture for graph mining on processing-in-memory systems. In *MICRO-54: 54th Annual IEEE/ACM International Symposium on Microarchitecture*, page 282–297, New York, NY, USA. Association for Computing Machinery.
- Besta, M., Miglioli, C., Labini, P. S., Tětek, J., Iff, P., Kanakagiri, R., Ashkboos, S., Janda, K., Podstawski, M., Kwaśniewski, G., Gleinig, N., Vella, F., Mutlu, O., and Hoefler, T. (2022). Probgraph: high-performance and high-accuracy graph mining with probabilistic set representations. In *Proceedings of the International Conference on High Performance Computing, Networking, Storage and Analysis*, Dallas, Texas. IEEE Press.
- Easley, D. and Kleinberg, J. (2010). *Networks, Crowds, and Markets: Reasoning about a Highly Connected World*. Cambridge University Press, USA.
- Har-Peled, S. and Sharir, M. (2011). Relative (p, ϵ) -approximations in geometry. *Discrete Comput. Geom.*, 45(3):462–496.
- Menczer, F., Fortunato, S., and Davis, C. (2020). *A First Course in Network Science*. Cambridge University Press, UK.
- Newman, M. (2010). *Networks: An Introduction*. Oxford University Press, Inc., UK.
- Ribeiro, V. M. and Vignatti, A. L. (2025). Efficient approximations of neighborhood intersection in large graphs via sampling. Technical report, Federal University of Paraná.
- Shalev-Shwartz, S. and Ben-David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press, UK.
- Walker, A. (1974). New fast method for generating discrete random numbers with arbitrary frequency distributions. *Electronics Letters*, 10:127–128.