

## КЛАСТЕРНЫЙ КОЭФФИЦИЕНТ В МОДЕЛИ ПРОСТРАНСТВЕННОГО ПРЕДПОЧТИТЕЛЬНОГО ПРИСОЕДИНЕНИЯ

© 2018 Л. Исхаков<sup>1,\*</sup>, М. Миронов<sup>1</sup>, Л. Прохоренкова<sup>1,2</sup>,  
Б. Камински (B. Kaminski)<sup>3</sup>, П. Пралат (P. Pralat)<sup>4</sup>

Представлено академиком РАН В.В. Козловым 14.02.2018 г.

Поступило 22.02.2018 г.

Рассматривается кластерная структура графа в модели пространственного предпочтительного соединения, для которой уже было показано сходство с реальными сетями во многих аспектах. Изучается поведение локального кластерного коэффициента, а именно, рассматривается асимптотическое поведение его среднего значения по всем вершинам графа некоторой степени при стремлении размера графа к бесконечности. Данная величина не была рассмотрена ранее и отражает типичную зависимость кластерной структуры в окрестности некоторой вершины от её степени в графе. Кроме того, показано наличие с высокой вероятностью вершины, для которой значение коэффициента отличается от его среднего значения.

В последнее время в научной литературе большое внимание уделяется сложным сетям. Исследования показывают, что сети, полученные из реальных данных, таких как социальные сети и др., имеют ряд типичных свойств, например малый диаметр, степенное распределение степеней вершин, кластерную структуру [10]. Для анализа и предсказания свойств растущих с каждым днём сетей было предложено достаточно много математических моделей случайных графов.

Так, например, диаметр случайного дистанционного графа частично изучен в работе [3]. Часто также моделирование сложных сетей используют для анализа социальных сетей. В работе [2] представлен результат о времени смешивания марковских цепей при построении искусственных социальных графов.

Наиболее изученным свойством сложных сетей является распределение их степеней вершин. Для большинства реальных сетей это распределение хорошо приближается степенным распределением с параметром  $\gamma$ , который обычно находится в интервале (2, 3) [11]. Другое важное свойство реальных сетей — их кластерная структура. Одним из способов её измерения является *кластерный коэффициент*. В некотором смысле его значение

есть вероятность для двух соседей одной вершины быть смежными между собой. В литературе предложено два классических определения: средний локальный кластерный коэффициент и глобальный кластерный коэффициент (формальные определения даны в разделе 2). Было показано, что во многих реальных сетях оба этих коэффициента стремятся к положительной константе с увеличением размера сети [10].

Предметом данного исследования является кластерная структура модели *пространственного предпочтительного присоединения* (*Spatial Preferential Attachment, SPA*), которая была предложена в работе [1]. Эта модель естественным образом сочетает в себе предпочтительное присоединение и геометрическую составляющую. Особенно нас будет интересовать средний локальный кластерный коэффициент  $C(d)$  как функция от степени  $d$  вершины. Модель SPA хорошо изучена, было показано, что она схожа с реальными сетями во многих аспектах. Например, в [1] доказан степенной закон распределения степеней вершин. Кластерный коэффициент  $C(d)$  для этой модели не был изучен, хотя некоторые кластерные свойства проанализированы в [4]. В работах [4] и [5] доказано, что средний локальный кластерный коэффициент сходится по вероятности к положительной константе, если и только если распределение степеней вершин имеет конечную дисперсию.

### 1. Модель SPA

#### 1.1. Определения

Модель SPA комбинирует предпочтительное присоединение и структуру метрического

1) Лаборатория продвинутой комбинаторики и сетевых приложений, Московский физико-технический институт (государственный университет), Долгопрудный

2) Управление машинного интеллекта и исследований, Яндекс, Москва, Россия

3) Warsaw School of Economics, Warsaw, Poland

4) Ryerson University, Toronto, Canada

\*E-mail: lenar-iskhakov@yandex.ru

пространства, в котором лежат вершины. Достигается это за счёт наличия у каждой вершины “сферы влияния”. Параметрами модели являются вероятность создания ребра  $p \in [0,1]$  и две константы  $A_1, A_2$ , где

$$0 < A_1 < \frac{1}{p}, A_2 > 0,$$

которые отвечают за объём сфер влияния вершин. Вершины в данной модели – это точки  $m$ -мерного единичного гиперкуба  $S = [0,1]^m$  с торической метрикой на нём, индуцированной нормой  $L_k$ , т.е.

$$d(x, y) = \min\{\|x - y + u\|_k : u \in \{-1, 0, 1\}^m\} \quad \forall x, y \in S.$$

В модели SPA генерируется последовательность случайных графов  $\{G_t\}$ , где  $G_t = (V_t, E_t)$ ,  $V_t \subseteq S$ . Пусть  $\deg^-(v, t)$  – входящая степень вершины  $v$  в графе  $G_t$ , и  $\deg^+(v, t)$  – её исходящая степень. Тогда «сфера влияния»  $S(v, t)$  вершины  $v$  в момент времени  $t \geq 1$  – это шар с центром в  $v$  и объёма:

$$|S(v, t)| = \min\left\{\frac{A_1 \deg^-(v, t) + A_2}{t}, 1\right\}.$$

Последовательность графов строится постепенно, начиная с пустого графа  $G_0$  в момент времени  $t = 0$ . Далее для каждого  $t > 1$  граф  $G_t$  получается из графа  $G_{t-1}$  следующим образом. Сначала случайно и равномерно из гиперкуба  $S$  выбирается новая вершина  $v_t$ , которая добавляется к множеству вершин  $V_{t-1}$ . Затем независимо для каждой такой вершины  $u \in V_{t-1}$ , что  $v_t \in S(u, t-1)$ , направленное ребро

$(v_t, u)$  проводится с вероятностью  $p$ . Таким образом, вероятность того, что ребро  $(v_t, u)$  будет добавлено в момент времени  $t$ , равна  $p|S(u, t-1)|$ .

На рис. 1 представлен граф в SPA-модели.

### 1.2. Свойства модели

В этом разделе мы приведём некоторые изученные ранее свойства и приложения SPA-модели. Теорема 1.1 из [1] утверждает, что SPA-модель генерирует граф со степенным распределением входящих степеней вершин с параметром  $1+1/(pA_1)$ . С другой стороны, средняя исходящая степень асимптотически равна  $pA_2/(1-pA_1)$ . Теорема 1.3. В [6] показано, что SPA-модель хорошо приближает графовую структуру социальных графов, полученных из сети Facebook. Обычно предполагается, что распределение вершин в гиперкубе  $S$  равномерно [7], однако в [8] рассматриваются и неравномерные распределения, что более реалистично для некоторых приложений модели.

## 2. Кластерный коэффициент

Кластерный коэффициент измеряет, какова вероятность того, что два соседа одной вершины соединены ребром. В литературе предложено несколько определений кластерного коэффициента.

Глобальный кластерный коэффициент  $C_{\text{glob}}(G)$  – отношение утроенного количества




Рис. 1 Граф в SPA модели при  $t = 500, p = 1$  и  $A_1 = A_2 = 1$

треугольников к количеству пар смежных рёбер в графе  $G$ . Другими словами, если мы выберем случайную пару смежных рёбер, то  $C_{\text{glob}}(G)$  будет вероятностью того, что три данные вершины образуют треугольник. Глобальный кластерный коэффициент в модели SPA рассматривался в [4, 5]. Мы же, в свою очередь, рассмотрим *локальный кластерный коэффициент*. Определим его для неориентированного графа  $G = (V, E)$ . Пусть  $N(v)$  – множество соседей вершины  $v$ ,  $|N(v)| = \text{deg}(v)$ . Для любого  $B \subseteq V$  пусть  $E(B)$  – множество рёбер в подграфе, индуцированном на множество  $B$ :

$$E(B) = \{(u, w) \in E : u, w \in B\}.$$

Тогда *кластерный коэффициент* вершины  $v$  определяется следующим образом:

$$c(v) = \frac{|E(N(v))|}{\binom{\text{deg}(v)}{2}}.$$

Видно, что  $0 \leq c(v) \leq 1$ . Усреднением по всем вершинам степени  $d$  получаем  $C(d)$  – средний локальный коэффициент по вершинам степени  $d$ :

$$C(d) = \frac{\sum_{v: \text{deg}(v)=d} c(v)}{|\{v : \text{deg}(v) = d\}|}.$$

Далее, мы будем использовать обозначения  $c(v, t)$  и  $C(d, t)$ , соответствующие графам в момент времени  $t$ .

Локальный кластерный коэффициент  $C(d)$  в различных сетях и их моделях был широко изучен как с теоретической, так и с эмпирической точки зрения. Например, было показано, что в реальных сетях  $C(d)$  обычно убывает как  $d^{-\psi}$  для некоторого  $\psi > 0$ . В частности, [14] показано, что  $C(d)$  может быть хорошо приближен с помощью  $d^{-1}$  для некоторых больших сетей, а в [15] получено степенное убывание  $C(d)$  с параметром 0,75. Локальный кластерный коэффициент был изучен в ряде вероятностных моделей сложных сетей. Например, в [9] показано, что для некоторых таких моделей  $C(d) \sim d^{-1}$ . Мы получили схожее поведение и для модели SPA.

Напомним, что SPA-модель генерирует ориентированный граф, поэтому формально определим локальный кластерный коэффициент для ориентированного случая. Пусть  $N^-(v, t) \subseteq V_t$  – множество вершин, из которых ведёт ребро в вершину  $v$  в момент времени  $t$ . Тогда интересующая нас величина опре-

деляется как

$$c^-(v, t) = \frac{|E(N^-(v, t))|}{\binom{\text{deg}^-(v, t)}{2}}.$$

Как и в неориентированном случае, определим

$$C^-(d, t) = \frac{\sum_{v: \text{deg}^-(v, t)=d} c^-(v, t)}{|\{v : \text{deg}^-(v, t) = d\}|}.$$

### 3. Результаты

Все результаты, которые будут представлены в этом разделе, носят асимптотический характер. Это значит, что некоторое свойство последовательности графов  $\{G_n\}$  рассматривается при  $n$ , стремящемся к бесконечности. Мы говорим, что событие выполнено *асимптотически почти наверное* (а.п.н.), если оно выполнено с вероятностью, стремящейся к единице при  $n \rightarrow \infty$ . Также для множества  $S$  мы говорим, что *почти все* элементы из  $S$  обладают некоторым свойством  $P$ , если число элементов  $S$ , не удовлетворяющих свойству  $P$ , есть  $o(|S|)$ . Наконец, мы используем обозначение  $f \ll g$  для  $f = o(g)$  и  $f \gg g$  для  $g = o(f)$ .

Как было сказано ранее, мы хотим показать, что SPA-модель схожа с реальными большими сетями в терминах локального кластерного коэффициента. А именно, мы покажем, что данный коэффициент в SPA-модели для вершин степени  $k$  может быть хорошо приближен функцией  $\frac{1}{k}$  при  $n \rightarrow \infty$ .

Мы рассмотрим кластерный коэффициент для ориентированного графа, однако стоит иметь в виду, что аналогичные утверждения верны и для соответствующего неориентированного графа, который получен из исходного заменой всех направленных рёбер на ненаправленные.

Для SPA-модели мы можем не только оценить кластерный коэффициент  $C^-(d, n)$ , но и сформулировать некоторое вероятностное утверждение для отдельно взятой вершины  $v$ . Однако для этого её входящая степень должна быть довольно большой.

Изложение начнём с теоремы, которая показывает негативный для нашей цели результат. А именно, если некоторая вершина  $v$  итоговой входящей степени  $k$  оказалась в зоне плотного скопления более  $p$  а н н и х вершин, то её кластерный коэффициент может оказаться довольно большим (значительно больше, чем  $k^{-1}$ ). Из этого следует, что утверждение о том, что для всех без исключения

вершин в графе локальный кластерный коэффициент такой, как мы ожидаем, неверно.

*Теорема 1.* Пусть

$$C = 5 \ln \left( \frac{1}{p} \right)$$

и

$$\xi = \xi(n) = \frac{1}{(\omega(\ln \ln n)^2 (\ln \ln \ln n)) = o(1)}$$

для некоторого  $\omega = \omega(n)$ , стремящегося к бесконечности при  $n \rightarrow \infty$ .

Предположим, что  $k = k(n)$  и  $2 \leq k \leq n^\xi$ .

Тогда а.п.н. существует такая вершина  $v$ , что  $\deg^-(v, n) \sim k$  и выполнено

(i)  $c^-(v, n) = 1$ , при условии  $2 \leq k \leq \sqrt{\frac{\ln n}{C}}$

(ii)  $c^-(v, n) = \Omega(1) \gg \frac{1}{k}$ , при условии

$$\sqrt{\frac{\ln n}{C}} \leq k \leq \frac{\ln n}{\ln \ln n}$$

(iii)  $c^-(v, n) \gg \frac{(\ln \ln n)^2 (\ln \ln \ln n)}{k} \gg \frac{1}{k}$

при условии

$$\frac{\ln n}{\ln \ln n} \leq k \leq n^\xi$$

Однако несмотря на это, почти все вершины достаточно большой степени имеют кластерный коэффициент порядка  $1/k$ , что сформулировано в следующей теореме.

*Теорема 2.* Пусть  $\varepsilon, \delta \in (\frac{0,1}{2})$  некоторые константы, а  $k = k(n) \leq n^{pA_1 - \varepsilon}$ . Пусть  $X_k$  — подмножество вершин графа  $G_n$ , в котором каждая вершина имеет входящую степень между  $(1 - \delta)k$  и  $(1 + \delta)k$ . Тогда а.п.н. выполнено следующее:

(i) почти все вершины из  $X_k$  имеют

$$c^-(v, n) = \Theta\left(\frac{1}{k}\right), \text{ при условии } k \gg \ln^{C_1} n$$

где

$$C_1 = \frac{4 + (4pA_1 + 2)}{(pA_1(1 - pA_1))}$$

(ii) средний кластерный коэффициент  $c^-(v, n)$  вершин из  $X_k$  есть  $\Theta\left(\frac{1}{k}\right)$ , т.е.

$$\frac{1}{|X_k|} \sum_{v \in X_k} c^-(v, n) = \Theta\left(\frac{1}{k}\right),$$

при условии  $k \gg \ln^{C_2} n$ , где

$$C_2 = \frac{4 + (4pA_1 + 2)}{(pA_1(1 - pA_1))}$$

Приведённые результаты показывают схожесть модели SPA и реальных графов в терминах локального кластерного коэффициента, а также дают подробное представление о значении этого коэффициента в различных случаях.

### СПИСОК ЛИТЕРАТУРЫ

1. Aiello W., Bonato A., Cooper C., Janssen J., Pralat P. A Spatial Web Graph Model with Local Influence Regions. *Internet Math.* 2009. V. 5. P. 175-196.
2. Avrachenkov K., Iskhakov L., Mironov M. On Mixing in Pairwise Markov Random Fields with Application to Social Networks. In Proc. XIII Intern. Workshop WAW. 2016. Montreal, QC, Canada, December 14-15. 2016. p.127–139. Montreal. Springer, 2016.
3. Iskhakov L., Mironov M. Diameters of Random Distance Graphs. *J. of Math. Sci.* 2017. №227(4). P. 407-418.
4. Jacob E., Morters, P. A. Spatial Preferential Attachment Model with Local Clustering. In *International Workshop on Algorithms and Models for the Web-Graph*. B: Springer. 2013. P. 14-25.
5. Jacob E., Morters P., et al. Spatial Preferential Attachment Networks: Power Laws and Clustering Coefficients. //The Ann. App. Probab. 2015. №25(2). P. 632-662.
6. Janssen J., Hurshman M., Kalyaniwalla N. Model Selection for Social Networks Using Graphlets//*Internet Mathematics*. 2013. V. 8. №4. P. 338-363.
7. Janssen J., Pralat P., Wilson, R. Geometric Graph Properties of the Spatial Preferred Attachment Model. //Adv. in App. Math. 2013. V.50. P. 243-267.
8. Janssen J., Pralat P., Wilson R. Non-uniform Distribution of Nodes in the Spatial Preferential Attachment Model. //Internet Mathematics. 2016. V. 12. №1-2. P. 121-144.
9. Krot A. and Prokhorenkova L. O. Local Clustering Coefficient in generalized Preferential Attachment Models//In: Intern.Workshop on Algorithms and Models for the Web-Graph. B: Springer. 2015. P. 15-28.
10. Newman M. E. The structure and Function of Complex Networks. //SIAM review, 2003, v. 45(2): p.167–256.
11. Newman M. E. Power Laws, Pareto Distributions and Zipf's Law//Contemp. physics. 2005. V. 46. №5. P. 323-351.
12. Prokhorenkova L.O. General Results on Preferential Attachment and Clustering

Coefficient//Optim. Letters. 2017. V. 11. №2. P. 279-298.

13. Raigorodskii A. Small Subgraphs in Preferential Attachment Networks.//Optim. Letters. 2017. V. 11. №2. P. 249-257.

14. Ravasz E., Barabasi A.-L. Hierarchical

Organization in Complex Networks//Phys. Rev. E. 2003. V. 67. №2: 026112.

15. Vazquez A., Pastor-Satorras R., Vespignani A., Large-scale Topological and Dynamical Properties of the Internet//Phys. Rev. E. 2002. V. 65. №6: 066130.